

推荐序 1

“互联网+”的大潮催生了诸如“互联网+外卖”、“互联网+打车”、“互联网+家政”等众多商业模式创新和创业佳话。而当“互联网+”已被写入教科书并成为传统行业都在积极践行的发展道路时，过去一年科技界的聚光灯却被人工智能和深度学习所创造的一个个奇迹所占据。从阿尔法狗肆虐围棋界，到人工智能创业大军的崛起，都预示着我们即将步入“AI+”的时代：“AI+教育”、“AI+媒体”、“AI+医学”、“AI+配送”、“AI+农业”，等等，将会层出不穷。

AI 在近期的爆发离不开数据“质”和“量”的提升，离不开高性能计算平台的发展，更离不开算法的进步，而深度学习则成为了推动算法进步中的一个主力军。TensorFlow 作为谷歌开源的深度学习框架，包含了谷歌过去 10 年间对于人工智能的探索和商业应用。谷歌的自驾车、搜索、购物、广告、云计算等产品，都无时无刻不在利用类似 TensorFlow 的深度学习算法将数据的价值最大化，从而创造巨大的商业价值。

TensorFlow 作为一个开源框架，在极短时间内迅速圈粉并已成为 github.com 上耀眼的明星。然而，掌握深度学习需要较强的理论功底，用好 TensorFlow 又需要足够的实践和解析。开源项目和代码本身固然重要，但更重要的是使用者的经验和领域知识，以及如何将底层技术或工具采用最佳实践和模式来解决现实问题。我与作者共事多年，浏览本书后深深体会到该作品是作者在谷歌多年分布式深度学习实践经验和其理论才学的浓缩，也相信这本从入门到高级实践的读物能够为每个读者带来一个精神盛宴，并帮助计算机技术从业者在各自的业务领域打开新的思路、插上新的翅膀。

张鑫

杭州才云科技有限公司联合创始人 CEO、Carnegie Mellon University 计算机博士

推荐序 2

自 2015 年 11 月发布以来，TensorFlow 在 GitHub 上迅速受到广泛关注。TensorFlow 的一个突出特点，是它很好地兼顾了学术研究和工业生产的不同需求。一方面，TensorFlow 的灵活性使得研究人员能够利用它快速实现最新的模型设计；另一方面，TensorFlow 强大的分布式支持，对工业界在海量数据集上进行的模型训练也至关重要。

以我供职的谷歌翻译组为例，在研发最新的神经网络翻译模型过程中，我们既需要快速灵活地尝试学术界各类最新的想法，又需要成熟、高效的分布式训练系统，以便在十亿句量级的训练数据上训练最终模型。TensorFlow 的特性使我们只需维护一套代码，就能够高效兼顾这两方面的工作。模型训练完成之后，我们又借助 TensorFlow 搭建了一个高性能、低延迟的在线翻译服务。目前谷歌翻译每天完成大约千亿词量级的文字翻译任务，其中超过 35% 是通过 TensorFlow 进行的。

TensorFlow 还有着强大的可移植性，支持 GPU、CPU、安卓、iOS 等多种计算平台。受益于这一特性，开发者可以在移动平台上开发复杂的深度学习应用。仍以翻译为例，谷歌翻译应用中广受好评的图片即时翻译功能，就是依赖于移动平台上的 TensorFlow，使用用户的手机本地完成计算的。这一功能可以帮助人们摆脱语言和手机网络的约束，更加自由地体验全球各地的风土人情。

谷歌已经将 TensorFlow 大规模应用于数十项产品的研发中，而在谷歌以外，TensorFlow 也逐渐得到广泛应用。从国内的小米、京东，到硅谷的 Uber、Airbnb、Twitter 等，都已经开始采用 TensorFlow 进行生产实践。多伦多大学、加州大学伯克利分校等著名高校，也将 TensorFlow 用于教学当中，斯坦福大学更是专门开设了“TensorFlow for Deep Learning Research”课程，帮助学生深入理解这一深度学习领域的重要工具。

作者郑泽宇是我的多年好友，他对于机器学习的学术研究和工业应用方面都有着极为丰富的经验。这本教程从深入浅出，涵盖了深度学习中常见算法的理论基础和 TensorFlow 实现两方面内容。相信这本书能帮助读者在最短时间内理解深度学习并熟练应用 TensorFlow，在这一当前极为活跃的领域展开工程实践。

梁博文
工程师，谷歌翻译团队

推荐序 3

深度学习带来的技术革命波及甚广，学术界同样早已从中受益，将深度学习广泛应用到各个学科领域。深度学习源自“古老”的神经网络技术，既标志着传统神经网络的卷土重来，也藉由 AlphaGo 碾压人类围棋一役，开启了 AI 爆炸式发展的大幕。机器学习为人工智能指明道路，而深度学习则让机器学习真正落地。作为高等教育工作者，让学生了解和跟上最新技术发展的意义不言而喻。而深度学习的重要性，从近来国内外互联网巨擘对未来的展望中可见端倪——以深度学习照耀下的人工智能技术，毫无疑问是下一个时代的主角和支柱。

然而，目前深度学习的相关资料，尤其是像 TensorFlow 这种引领未来趋势的新技术的学习资料，普遍存在明显缺憾。

其一，中文资料非常少，而且信息零散、不成系统。这篇文章里讲一个算法，那个博客里介绍一个应用，很难让学生形成一个完整的、全局的概念体系。

其二，已有的深度学习资料大多偏重理论，对概率、统计等数学功底有很高的要求，不易激发学生的兴趣。

而这些现存问题，也正是我对泽宇这部著作寄予厚望的原因——这是一本非常适合高校学生走近深度学习的入门读物。因为它从实际问题出发，可以激发读者的兴趣，让读者可以快速而直观地享受到解决问题的成就感。同时，此书理论与实践并重，既介绍了深度学习的基本概念，为更加深入地研究深度学习奠定基础；又给出了具体的 TensorFlow 样例代码，让读者可以将学习成果直接运用到实践中。

我非常相信也衷心希望，有志参与深度学习未来大潮的莘莘学子，能凭借此书更快速、更扎实地开启深度学习之旅，并通过 TensorFlow 来实现深度学习常用算法，从而登堂入室，最终成为 AI 的真正驾驭者。

张铭

北京大学信息学院教授

前言

“深度学习”这个词在过去的一年之中已经轰炸了媒体、技术博客甚至朋友圈。这也许正是你会读到本书的原因之一。数十年来，人工智能技术虽不断发展，但像深度学习这样在学术界和工业界皆具颠覆性的技术实在是十年难遇。可惜的是，理解和灵活运用深度学习并不容易，尤其是其复杂的数学模型，让不少感兴趣的同学“从入门到放弃”。更糟糕的是，因为深度学习技术的飞速发展，而写书、出版的过程又非常复杂，不论是英文还是中文，都很难找到从实战出发的深度学习参考书。关于当前最新最火的深度学习框架 TensorFlow 的书籍更是空缺。这正是作者在工作之余，熬夜写这本书的动力。作者本人作为一枚标准码农、创业党，希望这本书能够帮助码农和准码农们绕过深度学习复杂的数据公式，通过本书的大量样例代码快速上手深度学习，解决工作、学习中的实际问题。

2016 年初，作者和小伙伴从美国谷歌辞职，回到祖国杭州联合创办了才云科技 (Caicloud.io)，为企业提供人工智能平台和解决方案，在作者回国之初，很多企业都展示出了对于 TensorFlow 浓厚的兴趣。然而在深度交流之后，作者发现虽然 TensorFlow 是一款非常容易上手的工具，但是深度学习的技术目前并不是每一个企业都掌握的。为了让更多的个人和企业可以享受到深度学习技术带来的福利，作者与电子工业出版社的张春雨主编一拍即合，开始了本书的撰写工作。

使用 TensorFlow 实现深度学习是本书重点介绍的对象。本书将从 TensorFlow 的安装开始，逐一介绍 TensorFlow 的基本概念、使用 TensorFlow 实现全连接深层神经网络、卷积神经网络和循环神经网络等深度学习算法。在介绍使用 TensorFlow 实现不同的深度学习算法的同时，作者也深入浅出地介绍了这些深度学习算法背后的理论，并给出了这些算法可以解决的具体问题。在本书中，作者避开了枯燥复杂的数学公式，从实际问题出发，在实践中介绍深度学习的概念和 TensorFlow 的用法。在本书中，作者还介绍了 TensorFlow 并行化输入数据处理流程、TensorBoard 可视化工具以及带 GPU 的分布式 TensorFlow 使用方法。

TensorFlow 是一个飞速发展的工具。本书在写作时最新的版本为 0.9.0，然而到本书出版时，谷歌已经推出了 TensorFlow 1.0.0。为了让广大读者更好地理解和试用书中的样例代

码, 我们提供了一个公开的 GitHub 代码库来维护不同 TensorFlow 版本的样例程序。该代码库的网址为 <https://github.com/caicloud/tensorflow-tutorial>。在 Caicloud 提供的 TensorFlow 镜像 [cargo.caicloud.io/tensorflow/tensorflow:0.12.0](https://mirror.cnci.io/cargo.caicloud.io/tensorflow/tensorflow:0.12.0) 中也包含了本书的样例代码。作者衷心地希望各位读者能够从本书获益, 这也是对我们最大的支持和鼓励。对于书中出现的任何错误或者不准确的地方, 欢迎大家批评指正, 并发送邮件至 zeyu@caicloud.io。

读者也可登录博文视点官网 <http://www.broadview.com.cn> 下载本书代码或提交勘误信息。一旦勘误信息被作者或编辑确认, 即可获得博文视点奖励积分, 可用于兑换电子书。读者可以随时浏览图书页面, 查看已发布的勘误信息。

致谢

在此我特别感谢为此书做出贡献的每一个人。感谢每一位读者, 希望书里的干货值得您宝贵的精力投入。要记得好评哦, 亲!

首先, 我要感谢才云科技 (Caicloud.io) 小伙伴们对我的大力支持。在紧张的创业环境中, CEO 张鑫给了我极大的支持和鼓励, 让我有足够的时间投入到本书中。特别感谢为此书完成校验以及代码整理工作的数据工程师易明轩, 为此书提出宝贵意见的大数据科学家何辉辉以及才云科技 TensorFlow as a Service 的产品开发者李恩华。

然后, 我要感谢我的妻子温苗苗。作为本书的第一读者和美国卡内基梅隆大学 (Carnegie Mellon University) 计算机专业博士, 从最开始的内容安排到写作语言细节, 与她的讨论给我带来很多灵感。

我要感谢我的父母、岳父母, 没有他们一直以来的支持和帮助, 我不可能完成此书的写作。每当遇到困难的时候, 长辈们的鼓励是我前进的最大动力。

最后, 我要感谢电子工业出版社的张春雨编辑。无论在该书的定位上还是在具体的文字细节上, 张编辑都给了我非常多的建议。兵贵神速, 写书亦是如此。没有张春雨精确的策划和及时的敦促, 我也很难一鼓作气完成此书。

郑泽宇
2017 年 1 月

用户注册

轻松注册成为博文视点社区用户 (www.broadview.com.cn), 您即可享受以下服务。

- **下载资源:** 本书所提供的示例代码及资源文件均可在【下载资源】处下载。
- **提交勘误:** 您对书中内容的修改意见可在【提交勘误】处提交, 若被采纳, 将获赠博文视点社区积分 (在您购买电子书时, 积分可用来抵扣相应金额)。
- **与作者交流:** 在页面下方【读者评论】处留下您的疑问或观点, 与作者和其他读者一同学习交流。

页面入口: <http://www.broadview.com.cn/30959>

二维码:



目 录

第 1 章 深度学习简介	1
1.1 人工智能、机器学习与深度学习	2
1.2 深度学习的发展历程	6
1.3 深度学习的应用	10
1.3.1 计算机视觉	10
1.3.2 语音识别	13
1.3.3 自然语言处理	14
1.3.4 人机博弈	17
1.4 深度学习工具介绍和对比	19
小结	22
第 2 章 TensorFlow 环境搭建	24
2.1 TensorFlow 的主要依赖包	24
2.1.1 Protocol Buffer	24
2.1.2 Bazel	26
2.2 TensorFlow 安装	28
2.2.1 使用 Docker 安装	29
2.2.2 使用 pip 安装	31
2.2.3 从源代码编译安装	32
2.3 TensorFlow 测试样例	36
小结	37
第 3 章 TensorFlow 入门	39
3.1 TensorFlow 计算模型——计算图	39

3.1.1	计算图的概念	39
3.1.2	计算图的使用	40
3.2	TensorFlow 数据模型——张量	42
3.2.1	张量的概念	42
3.2.2	张量的使用	44
3.3	TensorFlow 运行模型——会话	45
3.4	TensorFlow 实现神经网络	47
3.4.1	TensorFlow 游乐场及神经网络简介	47
3.4.2	前向传播算法简介	50
3.4.3	神经网络参数与 TensorFlow 变量	53
3.4.4	通过 TensorFlow 训练神经网络模型	57
3.4.5	完整神经网络样例程序	61
	小结	64
第 4 章	深层神经网络	65
4.1	深度学习与深层神经网络	65
4.1.1	线性模型的局限性	66
4.1.2	激活函数实现去线性化	69
4.1.3	多层网络解决异或运算	72
4.2	损失函数定义	73
4.2.1	经典损失函数	74
4.2.2	自定义损失函数	78
4.3	神经网络优化算法	80
4.4	神经网络进一步优化	84
4.4.1	学习率的设置	84
4.4.2	过拟合问题	86
4.4.3	滑动平均模型	90
	小结	91
第 5 章	MNIST 数字识别问题	93
5.1	MNIST 数据处理	93
5.2	神经网络模型训练及不同模型结果对比	96
5.2.1	TensorFlow 训练神经网络	96
5.2.2	使用验证数据集判断模型效果	101

5.2.3 不同模型效果比较	102
5.3 变量管理	106
5.4 TensorFlow 模型持久化	111
5.4.1 持久化代码实现	111
5.4.2 持久化原理及数据格式	116
5.5 TensorFlow 最佳实践样例程序	125
小结	131
第 6 章 图像识别与卷积神经网络	133
6.1 图像识别问题简介及经典数据集	134
6.2 卷积神经网络简介	138
6.3 卷积神经网络常用结构	141
6.3.1 卷积层	141
6.3.2 池化层	146
6.4 经典卷积网络模型	148
6.4.1 LeNet-5 模型	149
6.4.2 Inception-v3 模型	155
6.5 卷积神经网络迁移学习	159
6.5.1 迁移学习介绍	159
6.5.2 TensorFlow 实现迁移学习	160
小结	168
第 7 章 图像数据处理	169
7.1 TFRecord 输入数据格式	169
7.1.1 TFRecord 格式介绍	170
7.1.2 TFRecord 样例程序	170
7.2 图像数据处理	172
7.2.1 TensorFlow 图像处理函数	173
7.2.2 图像预处理完整样例	182
7.3 多线程输入数据处理框架	184
7.3.1 队列与多线程	185
7.3.2 输入文件队列	189
7.3.3 组合训练数据 (batching)	192
7.3.4 输入数据处理框架	195

小结	197
第 8 章 循环神经网络	199
8.1 循环神经网络简介	199
8.2 长短时记忆网络 (LSTM) 结构	205
8.3 循环神经网络的变种	208
8.3.1 双向循环神经网络和深层循环神经网络	208
8.3.2 循环神经网络的 dropout	210
8.4 循环神经网络样例应用	211
8.4.1 自然语言建模	212
8.4.2 时间序列预测	222
小结	227
第 9 章 TensorBoard 可视化	228
9.1 TensorBoard 简介	228
9.2 TensorFlow 计算图可视化	230
9.2.1 命名空间与 TensorBoard 图上节点	230
9.2.2 节点信息	237
9.3 监控指标可视化	242
小结	247
第 10 章 TensorFlow 计算加速	248
10.1 TensorFlow 使用 GPU	248
10.2 深度学习训练并行模式	253
10.3 多 GPU 并行	256
10.4 分布式 TensorFlow	263
10.4.1 分布式 TensorFlow 原理	264
10.4.2 分布式 TensorFlow 模型训练	267
10.4.3 使用 Caicloud 运行分布式 TensorFlow	277
小结	282

第1章 深度学习简介

随着 AlphaGo 战胜李世石,人工智能和深度学习这些概念已经成为一个非常火的话题。谷歌 (Google)、脸书 (Facebook)、百度、阿里巴巴等一系列国内外大公司纷纷对外公开宣布了人工智能将作为他们下一个战略重心。在类似 AlphaGo、无人驾驶汽车等最新技术的背后,深度学习是推动这些技术发展的核心力量。“深度学习”是本书的核心概念。通过阅读本章,读者将从多个角度了解这一概念。人工智能、机器学习与深度学习这几个关键词时常出现在媒体新闻中,并错误地被认为是等同的概念。1.1 节将介绍人工智能、机器学习以及深度学习的概念,并着重解析它们之间的关系。这一节将从不同领域需要解决的问题入手,依次介绍这些领域的基本概念以及解决领域内问题的主要思路。在介绍完深度学习基本的概念之后,1.2 节将完整地介绍深度学习发展史。虽然“深度学习”这个名词是在最近几年才提出,但深度学习基于的神经网络算法却早在 20 世纪 40 年代就出现了。这一节将会介绍神经网络发展过程中的重大事件,并介绍深度学习研究领域的发展历程。

接着,1.3 节将从计算机视觉、语音识别、自然语言处理和人机博弈四个不同的方向介绍目前深度学习的应用。从 2012 年深度学习被成功应用于图像识别问题以来,研究人员一直在扩展它的应用范围和影响力。这一节既会介绍在不同方向上深度学习在学术界取得的成就,也会介绍工业界成功应用深度学习的案例。最后,1.4 节将引出本书的重点——TensorFlow。TensorFlow 是谷歌开源的一个计算框架,该计算框架可以很好地实现各种深度学习算法。这一节将简单介绍 TensorFlow 的特性以及它目前的应用场景。也将对比不同的开源深度学习工具,并通过具体的数字来说明 TensorFlow 相比其他工具的优势以及作者将 TensorFlow 作为本书介绍对象的原因。

1.1 人工智能、机器学习与深度学习^①

从计算机发明之初，人们就希望它能够帮助甚至代替人类完成重复性劳作。利用巨大的存储空间和超高的运算速度，计算机已经可以非常轻易地完成一些对于人类非常困难，但对计算机相对简单的问题。比如，统计一本书中不同单词出现的次数，存储一个图书馆中所有的藏书，或是计算非常复杂的数学公式，都可以轻松通过计算机解决。然而，一些人类通过直觉可以很快解决的问题，目前却很难通过计算机解决。这些问题包括自然语言理解、图像识别、语音识别，等等。而它们就是人工智能需要解决的问题。

计算机要像人类一样完成更多智能的工作，需要掌握关于这个世界海量的知识。比如要实现汽车自动驾驶，计算机至少需要能够判断哪里是路，哪里是障碍物。这个对人类非常直观的东西，但对计算机却是相当困难的。路有水泥的、沥青的，也有石子的甚至土路。这些不同材质铺成的路在计算机看来差距非常大。如何让计算机掌握这些人类看起来非常直观的常识，对于人工智能的发展是一个巨大的挑战。很多早期的人工智能系统只能成功应用于相对特定的环境（specific domain），在这些特定环境下，计算机需要了解的知识很容易被严格并且完整地定义。例如，IBM 的深蓝（Deep Blue）在 1997 年打败了国际象棋冠军卡斯帕罗夫。设计出下象棋软件是人工智能史上的重大成就，但其主要挑战不在于让计算机掌握国际象棋中的规则。国际象棋是一个特定的环境，在这个环境中，计算机只需要了解每一个棋子规定的行动范围和行动方法即可。虽然计算机早在 1997 年就可以击败国际象棋的世界冠军，但是直到 20 年后的今天，让计算机实现大部分成年人都是可以完成的汽车驾驶却仍然依旧十分困难。

为了使计算机更多地掌握开放环境（open domain）下的知识，研究人员进行了很多尝试。其中一个影响力非常大的领域是知识图库（Ontology^②）。WordNet 是在开放环境中建立的一个较大且有影响力的知识图库。WordNet 是由普林斯顿大学（Princeton University）的 George Armitage Miller 教授和 Christiane Fellbaum 教授带领开发的，它将 155287 个单词整理为了 117659 个近义词集（synsets）。基于这些近义词集，WordNet 进一步定义了近义词集之间的关系。比如同义词集“狗”属于同义词集“犬科动物”，他们之间存在种属关系（hypernyms/hyponyms）^③。除了 WordNet，也有不少研究人员尝试将 Wikipedia 中的知识整理成知识图库。谷歌的知识图库就是基于 Wikipedia 创建的。

① 本节部分内容参见：Goodfellow I, Bengio Y, Courville A. *Deep learning* [M]. The MIT Press, 2016.

② 知识图库 Ontology 有时又被称为 Knowledge Graph。Knowledge Graph 更多的是指代谷歌内部建立的知识图库，而 Ontology 更多指代的是知识图库这个学术领域。

③ 更多关于 WordNet 的信息可以参考其官方网站：<https://wordnet.princeton.edu/>。

虽然使用知识图库可以让计算机很好地掌握人工定义的知识，但建立知识图库一方面需要花费大量的人力物力，另一方面可以通过知识图库方式明确定义的知识有限，不是所有的知识都可以明确地定义成计算机可以理解的固定格式。很大一部分无法明确定义的知识，就是人类的经验。比如我们需要判断一封邮件是否为垃圾邮件，会综合考虑邮件发出的地址、邮件的标题、邮件的内容以及邮件收件人的长度，等等。这是收到无数垃圾邮件骚扰之后总结出来的经验。这个经验很难以固定的方式表达出来，而且不同人对垃圾邮件的判断也会不一样。如何让计算机可以跟人类一样从历史的经验中获取新的知识呢？这就是机器学习需要解决的问题。

卡内基梅隆大学（Carnegie Mellon University）的 Tom Michael Mitchell 教授在 1997 年出版的书籍 *Machine Learning*^①中对机器学习进行过非常专业的定义，这个定义在学术界内被多次引用。在这本书中对机器学习的定义为“如果一个程序可以在任务 T 上，随着经验 E 的增加，效果 P 也可以随之增加，则称这个程序可以从经验中学习”。通过垃圾邮件分类的问题来解释机器学习的定义。在垃圾邮件分类问题中，“一个程序”指的是需要用到的机器学习算法，比如逻辑回归算法；“任务 T”是指区分垃圾邮件的任务；“经验 E”为已经区分过是否为垃圾邮件的历史邮件，在监督式机器学习问题中，这也被称之为训练数据；“效果 P”为机器学习算法在区分是否为垃圾邮件任务上的正确率。

在使用逻辑回归算法解决垃圾邮件分类问题时，会先从每一封邮件中抽取对分类结果可能有影响的因素，比如说上文提到的发邮件的地址、邮件的标题及收件人的长度，等等。每一个因素被称之为一个特征（feature）。逻辑回归算法可以从训练数据中计算出每个特征和预测结果的相关度。比如在垃圾邮件分类问题中，可能会发现如果一个邮件的收件人越多，那么邮件为垃圾邮件的概率也就越高。在对一封未知的邮件做判断时，逻辑回归算法会根据从这封邮件中抽取得到的每一个特征以及这些特征和垃圾邮件的相关度来判断这封邮件是否为垃圾邮件。

在大部分情况下，在训练数据达到一定数量之前，越多的训练数据可以使逻辑回归算法对未知邮件做出的判断越精准。也就是说逻辑回归算法可以根据训练数据（经验 E）提高在垃圾邮件分类问题（任务 T）上的正确率（效果 P）。之所以说在大部分情况下，是因为逻辑回归算法的效果除了依赖于训练数据，也依赖于从数据中提取的特征。假设从邮件中抽取的特征只有邮件发送的时间，那么即使有再多的训练数据，逻辑回归算法也无法很好地利用。这是因为邮件发送的时间和邮件是否为垃圾邮件之间的关联不大，而逻辑回归算法无法从数据中习得更好的特征表达。这也是很多传统机器学习算法的一个共同的问题。

① Mitchell T M, Carbonell J G, Michalski R S. *Machine Learning* [M]. McGraw-Hill, 2003.

类似从邮件中提取特征，如何数字化地表达现实世界中的实体，一直是计算机科学中一个非常重要问题。如果将图书馆中的图书名称储存为结构化的数据，比如储存在 Excel 表格中，那么可以非常容易地通过书名查询一本书是否在图书馆中。如果图书的书名都是存在非结构化的图片中，那么要完成书名查找任务的难度将大大增加。类似的道理，如何从实体中提取特征，对于很多传统机器学习算法的性能有巨大影响。图 1-1 展示了一个简单的例子。如果通过笛卡尔坐标系 (cartesian coordinates) 来表示数据，那么不同颜色的结点无法被一条直线划分。如果将这些点映射到极角坐标系 (polar coordinates)，那么使用直线划分就很容易了。同样的数据使用不同的表达方式会极大地影响解决问题的难度。一旦解决了数据表达和特征提取，很多人工智能任务也就解决了 90%。

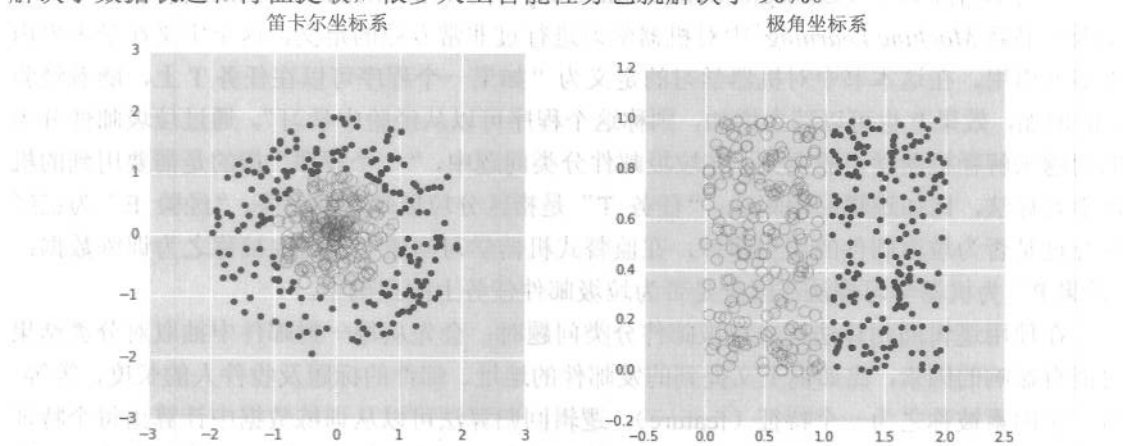


图 1-1 不同的数据表达对使用直线划分不同颜色结点的难度影响

然而，对许多机器学习问题来说，特征提取不是一件简单的事情。在一些复杂问题上，要通过人工的方式设计有效的特征集合，需要很多的时间和精力，有时甚至需要整个领域数十年的研究投入。例如，假设想从很多照片中识别汽车。现在已知的是汽车有轮子，所以希望在图片中抽取“图片中是否出现了轮子”这个特征。但实际上，要从图片的像素中描述一个轮子的模式是非常难的。虽然车轮的形状很简单，但在实际图片中，车轮上可能会有来自车身的阴影、金属车轴的反光，周围物品也可能会部分遮挡车轮。实际图片中各种不确定的因素让我们很难直接抽取这样的特征。

既然人工的方式无法很好地抽取实体中的特征，那么是否有自动的方式呢？答案是肯定的。深度学习解决的核心问题之一就是自动地将简单的特征组合成更加复杂的特征，并使用这些组合特征解决问题。深度学习是机器学习的一个分支，它除了可以学习特征和任务之间的关联以外，还能自动从简单特征中提取更加复杂的特征。图 1-2 中展示了深度学习和传统机器学习在流程上的差异。如图 1-2 所示，深度学习算法可以从数据中学习更加

复杂的特征表达，使得最后一步权重学习变得更加简单且有效。在图 1-3 中，展示了通过深度学习解决图像分类问题的具体样例。深度学习可以一层一层地将简单特征逐步转化成更加复杂的特征，从而使得不同类别的图像更加可分。比如图 1-3 中展示了深度学习算法可以从图像的像素特征中逐渐组合出线条、边、角、简单形状、复杂形状等更加有效的复杂特征。




图 1-2 传统机器学习和深度学习流程对比

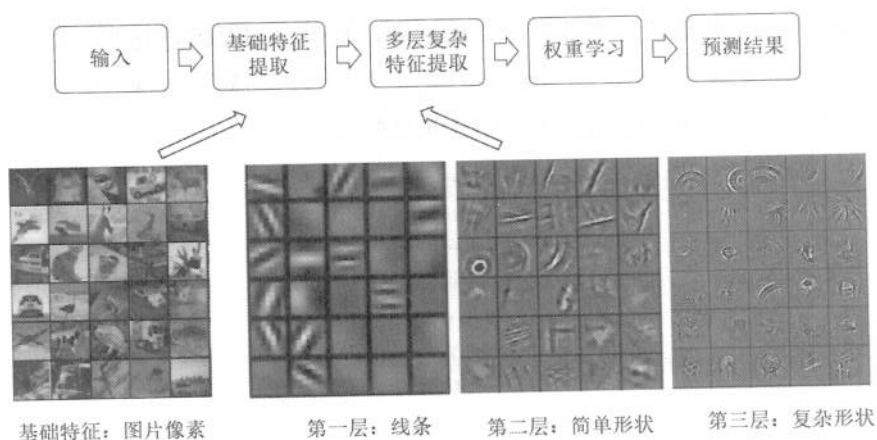


图 1-3 深度学习在图像分类问题上的算法流程样例

早期的深度学习受到了神经科学的启发，它们之间有非常密切的联系。科学家们在神经科学上的发现使得我们相信深度学习可以胜任很多人工智能的任务。神经科学家发现，如果将小白鼠的视觉神经连接到听觉中枢，一段时间之后小鼠可以习得使用听觉中枢“看”世界。这说明虽然哺乳动物大脑分为了很多区域，但这些区域的学习机制却是相似的。在这一假想得到验证之前，机器学习的研究者们通常会为不同的任务设计不同的算法。而且直到今天，学术机构的机器学习领域也被分为了自然语言处理、计算机视觉和语音识别等不同的实验室。因为深度学习的通用性，深度学习的研究者往往可以跨越多个研究方向

甚至同时活跃于所有的研究方向。下面的 1.3 节将具体介绍深度学习在不同方向的应用。

虽然深度学习领域的研究人员相比其他机器学习领域更多地受到了大脑工作原理的启发，而且媒体界也经常强调深度学习算法和大脑工作原理的相似性，但现代深度学习的发展并不拘泥于模拟人脑神经元和人脑的工作机理。模拟人类大脑也不再是深度学习研究的主导方向。我们不应该认为深度学习是在试图模仿人类大脑。目前科学家对人类大脑学习机制的理解还不足以为当下的深度学习模型提供指导。

现代的深度学习已经超越了神经科学观点，它可以更广泛地适用于各种并不是由神经网络启发而来的机器学习框架。值得注意的是，有一个领域的研究者试图从算法层理解大脑的工作机制，它不同于深度学习的领域，被称为“计算神经学”（computational neuroscience）。深度学习领域主要关注如何搭建智能的计算机系统，解决人工智能中遇到的问题。计算神经学则主要关注如何建立更准确的模型来模拟人类大脑的工作。

总的来说，人工智能、机器学习和深度学习是非常相关的几个领域。图 1-4 总结了它们之间的关系。人工智能是一类非常广泛的问题，机器学习是解决这类问题的一个重要手段。深度学习则是机器学习的一个分支。在很多人工智能问题上，深度学习的方法突破了传统机器学习方法的瓶颈，推动了人工智能领域的发展。




图 1-4 人工智能、机器学习以及深度学习之间的关系图

1.2 深度学习的发展历程

很多读者可能会认为深度学习是一门新技术，所以听到“深度学习的历史”也许会有些惊讶。事实上，目前大家所熟知的“深度学习”基本上是深层神经网络的一个代名词，而神经网络技术可以追溯到 1943 年。深度学习之所以看起来像是一门新技术，一个很重要的原因是它在 21 世纪初期并不流行。神经网络的发展史大致可以分为三个阶段，在本节中，

我们将简单介绍神经网络发展历史上的这三个阶段。

早期的神经网络模型类似于仿生机器学习，它试图模仿大脑的学习机理。最早的神经网络数学模型是由 Warren McCulloch 教授和 Walter Pitts 教授于 1943 年在论文 *A logical calculus of the ideas immanent in nervous activity*^①中提出的。在论文中，Warren McCulloch 教授和 Walter Pitts 教授模拟人类大脑神经元的结构提出了 McCulloch-Pitts Neuron 的计算结构。图 1-5 对比了人类神经元结构和 McCulloch-Pitts Neuron 结构。McCulloch-Pitts Neuron 结构大致模拟了人类神经元的工作原理，它们都有一些输入，然后将输入进行一些变换后得到输出结果。虽然人类神经元处理输入信号的原理目前还对我们来说还不是完全清晰，但 McCulloch-Pitts Neuron 结构使用了简单的线性加权求和的方式来模拟这个变换。将 n 个输入值提供给 McCulloch-Pitts Neuron 结构后，McCulloch-Pitts Neuron 结构会通过 n 个权重 w_1, w_2, \dots, w_n 来计算这 n 个输入的加权和，然后用这个加权和经过一个阈值函数得到一个 0 或 1 的输出。




图 1-5 人类神经元结构和 McCulloch-Pitts Neuron 结构对比图

举一个具体的例子来说明 McCulloch-Pitts Neuron 结构是如何解决实际问题的。假设要解决的问题是判断邮件是否为垃圾邮件，那么首先可以将从邮件里提取的 n 个特征值作为输入传入 McCulloch-Pitts Neuron 结构。McCulloch-Pitts Neuron 结构经过加权和及阈值函数处理可以得到一个 0 或者 1 的输出。如果这个输出为 0，那么相应的邮件为垃圾邮件；相反，如果这个输出为 1，那么相应的邮件不是垃圾邮件。

为了使这种方法可以精确地判断垃圾邮件，我们需要对 McCulloch-Pitts Neuron 结构中的权重进行特殊的设置。手动设置这些权重自然是一种选择，但通过人类经验设置权重的的方式既麻烦又很难达到最优的效果。为了让计算机能够更加自动且更加合理地设置权重大小，Frank Rosenblatt 教授于 1958 年提出了感知机模型 (perceptron)。感知机是首个可以根据样例数据来学习特征权重的模型。虽然 McCulloch-Pitts Neuron 结构和感知机模型极大地

① McCulloch W, Pitts W. *A Logical Calculus of the Ideas Immanent in Nervous Activity* [J]. *Bulletin of Mathematical Biophysics* Vol 5, 1943.

影响了现代机器学习，但是它们也存在非常大的局限性。

1969年由Marvin Minsky教授和Seymour Papert教授出版的*Perceptrons: An Introduction to Computational Geometry*一书中，证明了感知机模型只能解决线性可分问题，第4章中将会更加详细地介绍线性模型、线性可分问题。并明确指出了感知机无法解决异或问题。而且书中也指出在当时的计算能力下，实现多层的神经网络是不可能的事情。这些局限性导致了整个学术界对生物启发的机器学习模型的抨击。在书中，Marvin Minsky教授和Seymour Papert教授甚至做出了“基于感知机的研究注定将失败”的结论。这导致了神经网络的第一次重大低潮期，在之后的十多年内，基于神经网络的研究几乎处于停滞状态。

直到20世纪80年代末，第二波神经网络研究因分布式知识表达（distributed representation）和神经网络反向传播算法的提出而兴起。分布式的知识表达的核心思想是现实世界中的知识和概念应该通过多个神经元（neuron）来表达，而模型中的每一个神经元也应该参与表达多个概念。例如，假设要设计一个系统来识别不同颜色不同型号的汽车，那么可以有两种方法。第一种方法是设计一个模型使得模型中每一个神经元对应一种颜色和汽车型号的组合，比如“白色的小轿车”。如果有 n 种颜色， m 种型号，那么这样的表达方式需要 $n \times m$ 个神经元。另一种方法是使用一些神经元专门表达颜色，比如“白色”，另外一些神经元专门表达汽车型号，比如“小轿车”。这样“白色的小轿车”的概念可以通过这两个神经元的组合来表达。这种方式只需要 $n + m$ 个神经元就可以表达所有概念。而且即使在训练数据中没有出现概念“红色的卡车”，只要模型能够习得“红色”和“卡车”的概念，它也可以推广到概念“红色的卡车”。分布式知识表达大大加强了模型的表达能力，让神经网络从宽度的方向走向了深度的方向。这为之后的深度学习奠定了基础。在第4章中将通过具体的样例来说明深层的神经网络是可以很好地解决类似异或问题等线性不可分问题的。

除了解决了线性不可分问题，在20世纪80年代末，研究人员在降低训练神经网络的计算复杂度上也取得了突破性成就。David Everett Rumelhart教授、Geoffrey Everest Hinton教授和Ronald J. Williams教授于1986年在自然杂志上发表的*Learning Representations by Back-propagating errors*文章中首次提出了反向传播的算法（back propagation），此算法大幅降低了训练神经网络所需要的时间。直到今天，反向传播算法仍然是训练神经网络的主要方法。在神经网络训练算法改进的同时，计算机的飞速发展也使得80年代末的计算能力相比70年代有了突飞猛进的增长。于是神经网络在80年末到90年代初又迎来了发展的高峰期。如今使用得比较多的一些神经网络结构，比如卷积神经网络和循环神经网络，在这段时间都得到了很好的发展。Sepp Hochreiter教授和Juergen Schmidhuber教授于1991年提出的LSTM模型（long short-term memory）可以有效地对较长的序列进行建模，比如一句话或者一段文章。直到今天，LSTM都是解决很多自然语言处理、机器翻译、语音识别、时序

预测等问题最有效的方法。在第8章中将更加详细地介绍循环神经网络和LSTM模型。

然而，在神经网络发展的同时，传统的机器学习算法也有了突破性的进展，并在90年代末逐步超越了神经网络，成为当时机器学习领域最常用的方法。以手写体识别为例，在1998年，使用支持向量机（support vector machine）的算法可以把错误率降低到0.8%。这样的精确度是当时的神经网络无法达到的。导致这种情况主要有两个原因。首先，虽然训练神经网络的算法得到了改进，但在当时的计算资源下，要训练深层的神经网络仍然是非常困难的。其次，当时的数据量比较小，无法满足训练深层神经网络的需求。

随着计算机性能的进一步提高，以及云计算、GPU的出现，到2010年左右，计算量已经不再是阻碍神经网络发展的问题。与此同时，随着互联网+的发展，获取海量数据也不再困难。这让神经网络所面临的几个最大问题都得到解决，于是神经网络的发展也迎来了新的高潮。在2012年ImageNet举办的图像分类竞赛（ImageNet Large Scale Visual Recognition Challenge, ILSVRC）中，由Alex Krizhevsky教授实现的深度学习系统AlexNet赢得了冠军。自此之后，深度学习（deep learning）作为深层神经网络的代名词被大家所熟知。深度学习的发展也开启了一个AI的新时代。图1-6展示了“deep learning”这个词在最近十年谷歌搜索的热度趋势。从图中可以看出，从2012年之后，深度学习的热度呈指数级上升，到2016年时，深度学习已经成为了谷歌上最热门的搜索词。在2013年，深度学习被麻省理工（MIT）评为了年度十大科技突破之一^①。如今，深度学习已经从最初的图像识别领域扩展到了机器学习的各个领域。下面的1.3节将具体介绍目前深度学习在一些主要人工智能领域的应用。




图 1-6 “deep learning” 最近十年在谷歌搜索的热度趋势

（此图片基于谷歌趋势：<https://www.google.com/trends/>，词汇的热度按 0-100 分为 100 个等级：0 表示最低的热度，100 表示最流行的搜索词）

① 具体报道参见：<https://www.technologyreview.com/lists/technologies/2013/>。

1.3 深度学习的应用

深度学习最早兴起于图像识别，但是在短短几年时间内，深度学习推广到了机器学习的各个领域。如今，深度学习在很多机器学习领域都有非常出色的表现，在图像识别、语音识别、音频处理、自然语言处理、机器人、生物信息处理、化学、电脑游戏、搜索引擎、网络广告投放、医学自动诊断和金融等各大领域均有应用。本节将选取几个深度学习应用比较广泛的领域进行详细的介绍。但深度学习的应用不仅限于本节中所介绍的领域，在每个领域中的应用也不限于列举出的几个方面。

1.3.1 计算机视觉

计算机视觉是深度学习技术最早实现突破性成就的领域。在 1.2 节中介绍过，随着 2012 年深度学习算法 AlexNet 赢得图像分类比赛 ILSVRC (ImageNet Large Scale Visual Recognition Challenge) 冠军，深度学习开始受到学术界广泛的关注。ILSVRC 是基于 ImageNet 图像数据集举办的图像识别技术比赛，这个比赛在计算机视觉领域有极高的影响力。

图 1-7 展示了历年 ILSVRC 比赛的情况。从图 1-7 中可以看到，在深度学习被使用之前，传统计算机视觉的方法在 ImageNet 数据集上最低的 Top5 错误率为 26%^①。从 2010 年到 2011 年，基于传统机器学习的算法并没有带来正确率的大幅提升。在 2012 年时，Geoffrey Everest Hinton 教授的研究小组利用深度学习技术将 ImageNet 图像分类的错误率大幅下降到了 16%。而且，AlexNet 深度学习模型只是一个开始，在 2013 年的比赛中，排名前 20 的算法都使用了深度学习。从 2013 年之后，ILSVRC 上基本就只有深度学习算法参赛了。

从 2012 年到 2015 年间，通过对深度学习算法的不断研究，ImageNet 图像分类的错误率以每年 4% 的速度递减。这说明深度学习完全打破了传统机器学习算法在图像分类上的瓶颈，让图像分类问题得到了更好的解决。如图 1-7 所示，到 2015 年时，深度学习算法的错误率为 4%，已经成功超越了人工标注的错误率 (5%)，实现了计算机视觉研究领域的一个突破。

在 ImageNet 数据集上，深度学习不仅突破了图像分类的技术瓶颈，同时也突破了物体识别的技术瓶颈。物体识别的难度比图像分类更高。图像分类问题只需判断图片中包含哪一种物体。但在物体识别问题中，需要给出所包含物体的具体位置。而且一张图片中可能出现多个需要识别的物体。图 1-8 展示了 ILSVRC2013 物体识别数据集中的样例图片。每

^① 在 ImageNet 图像分类问题上，大部分研究都使用 Top5 错误率来评价模型优劣。第 6 章将更加详细地介绍 ImageNet 数据集。

一张图片中所有可以被识别的物体都被不同颜色的方框标注了出来。在 2013 年时，使用传统机器学习算法可以达到的 MAP (mean average precision)^① 值为 0.23。2016 年时，使用了 6 种不同深度学习模型的集成算法 (ensemble algorithm) 成功将 MAP 提高到了 0.66^②。




图 1-7 历年 ILSVRC 图像分类比赛最佳算法的错误率

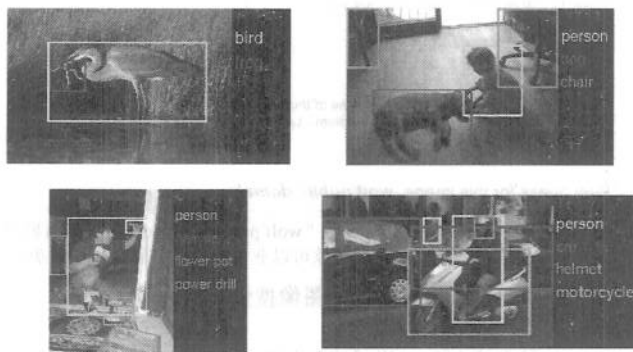


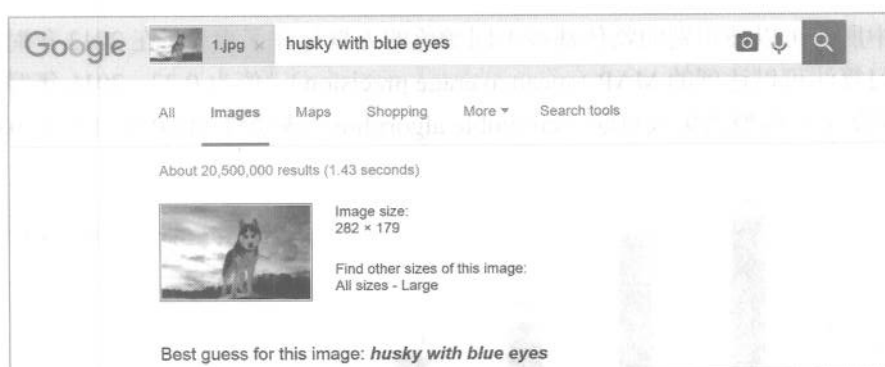
图 1-8 ILSVRC2013 物体识别数据集中的样例图片^③

在技术革新的同时，工业界也将图像分类、物体识别应用于各种产品中了。在谷歌，图像分类、物体识别技术已经被广泛应用于谷歌无人驾驶车、YouTube、谷歌地图、谷歌图像搜索等产品中。图 1-9 中展示了使用谷歌图像搜索来辨别动物。谷歌通过图像处理技术可以归纳出图片中的主要内容并实现以图搜图的功能。这些技术在国内的百度、阿里、腾讯等科技公司也已经得到了广泛的应用。

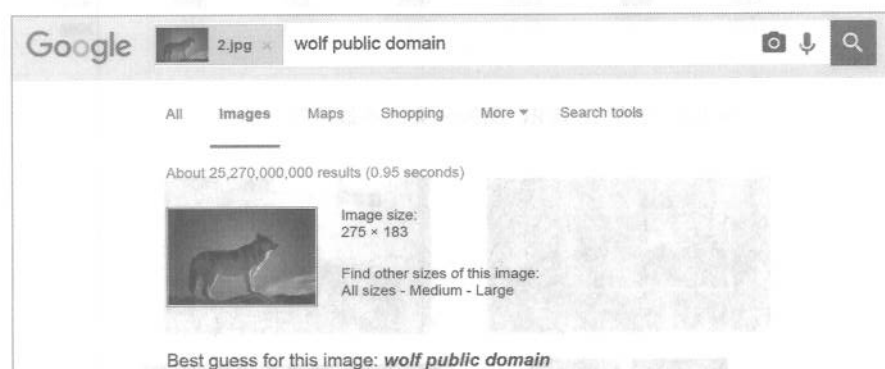
① <http://image-net.org/challenges/LSVRC/2013/index#task> 中有更多关于 ILSVRC2013 物体识别数据集的介绍。

② 数字出自 ILSVRC 官网：<http://image-net.org/challenges/LSVRC/2016/results>。

③ 图片来自于 ILSVRC 官网：<http://image-net.org/challenges/LSVRC/2013/>。



(a) 在谷歌图片搜索中提供一张哈士奇（一种狗）的图片，得到的结果为“husky with blue eyes（蓝色眼睛的哈士奇）”。虽然从图片中无法确认眼睛是否为蓝色，但是谷歌可以非常精确的识别出狗的品种。



(b) 在谷歌图片搜索中提供一张狼的图片，得到的结果为“wolf public domain（旷野上的狼）”。虽然这张图片和(a)中哈士奇图片非常接近，但是谷歌可以非常精确的识别动物的种类。

图 1-9 通过谷歌图像搜索识别动物

在物体识别问题中，人脸识别是一类应用非常广泛的技术。它既可以应用于娱乐行业，也可以应用于安防、风控行业。在娱乐行业中，基于人脸识别的相机自动对焦、自动美颜基本已经成为每一款自拍软件的必备功能。在安防、风控领域，人脸识别应用更是大大提高了工作效率并节省了人力成本。比如在互联网金融行业，为了控制贷款风险，在用户注册或者贷款发放时需要验证本人信息。个人信息验证中一个很重要的步骤是验证用户提供的证件和用户是同一个人。通过人脸识别技术，这个过程可以被更加高效地实现。

在深度学习得到广泛应用之前，基于传统的机器学习技术并不能很好地满足人脸识别的精度要求。人脸识别的最大挑战在于不同人脸的差异较小，有时同一个人在不同光照条件、姿态或者表情下脸部的差异甚至比不同人脸之间的差异更大。传统的机器学习算法很难抽象出足够有效的特征，使得学习模型既可以区分不同的个体，又可以尽量减少相同个体在不同环境中的变化。深度学习技术通过从海量数据中自动习得更加有效的人脸特征

表达,可以很好地解决这个问题。在人脸识别数据集 LFW^① (Labeled Faces in the Wild) 上,基于深度学习算法的系统 DeepID2 可以达到 99.47% 的识别率。

在计算机视觉领域,光学字符识别 (optical character recognition, OCR) 也是使用深度学习较早的领域之一。所谓光学字符识别,就是使用计算机程序将计算机无法理解的图片中的字符,比如数字、字母、汉字等符号,转化为计算机可以理解的文本格式。早在 1989 年, Yann LeCun 教授发表的论文 *Backpropagation Applied to Handwritten Zip Code Recognition* 将卷积神经网络成功应用到了识别手写邮政编码的问题上,达到了接近 95% 的正确率。在 MNIST 手写体数字识别数据集上,最新的深度学习算法可以达到 99.77% 的正确率,这也超过了人类的表现。第 5 章将更加详细地介绍 MNIST 手写体数字识别数据集。

光学字符识别在工业界的应用也十分广泛。在 21 世纪初期, Yann LeCun 教授将基于卷积神经网络的手写体数字识别系统应用于银行支票的数额识别,这个系统在 2000 年左右已经处理了美国全部支票数量的 10%~20%^②。谷歌也将数字识别技术用在了谷歌地图的开发中。谷歌实现的数字识别系统可以从谷歌街景图中识别任意长度的数字,并在 SVHN 数据集^③上可以达到 96% 的正确率^④。到 2013 年为止,这个系统已经帮助谷歌抽取了超过 1 亿个门牌号码,大大加速了谷歌地图的制作过程并节省了巨额的人力成本。而且,光学字符识别技术在谷歌的应用也不仅限于数字识别。谷歌图书通过文字识别技术将扫描的图书数字化,从而实现图书内容的搜索功能。

1.3.2 语音识别

深度学习在语音识别领域取得的成绩也是突破性的。2009 年深度学习的概念被引入语音识别领域,并对该领域产生了巨大的影响。在短短几年时间内,深度学习的方法在 TIMIT 数据集^⑤上将基于传统的混合高斯模型 (gaussian mixture model, GMM) 的错误率从 21.7% 降低到了使用深度学习模型的 17.9%。如此大的提高幅度很快引起了学术界和工业界的广泛关注。从 2010 年到 2014 年间,在语音识别领域的两大学术会议 IEEE-ICASSP 和

① 更多关于人脸识别数据集 LFW 的信息可以参考其官方网站: <http://vis-www.cs.umass.edu/lfw/>。

② 数字出自 Yann LeCun 教授在 CERN 研讨会上的报告 *Deep Learning and the Future of AI*。报告资料可以参考: <https://indico.cern.ch/event/510372/>。

③ SVHN 数据集是斯坦福大学开源的数据集,更多关于该数据的信息可以参考其官方网站: <http://ufldl.stanford.edu/housenumbers/>。

④ 数字参见: Goodfellow I J, Bulatov Y, Ibarz J, et al. *Multi-digit Number Recognition from Street View Imagery using Deep Convolutional Neural Networks* [J]. Computer Science, 2013.

⑤ 更多关于 TIMIT 数据集的信息可以参考其官方网站: <https://catalog.ldc.upenn.edu/ldc93s1>。

Interspeech 上, 深度学习的文章呈现出逐年递增的趋势。在工业界, 包括谷歌、苹果、微软、IBM、百度等在内的国内外大型 IT 公司提供的语音相关产品, 比如谷歌的 Google Now、苹果的 Siri、微软的 Xbox 和 Skype 等, 都是基于深度学习算法。

在 2009 年谷歌启动语音识别应用时, 使用的是在学术界已经研究了 30 年的混合高斯模型。到 2012 年时, 深度学习的语音识别模型已经取代了混合高斯模型, 并成功将谷歌语音识别的错误率降低了 20%, 这个改进幅度超过了过去很多年的总和。微软的研究人员通过大量实验得出, 使用深度学习的算法比使用混合高斯模型的算法更能够从海量数据中获益。随着数据量的加大, 使用深度学习模型无论在正确率的增长数值上还是在增长比率上都要优于使用混合高斯模型的算法^①。这样的增长在语音识别的历史上是从未出现过的, 而深度学习之所以能完成这样的技术突破, 最主要的原因是它可以自动地从海量数据中提取更加复杂且有效的特征, 而不是如高斯混合模型中需要人工提取特征。

基于深度学习的语音识别已经被应用到了各个领域, 其中最被大家所熟知的应该是苹果公司推出的 Siri 系统。Siri 系统可以根据用户的语音输入完成相应的操作功能, 这大大方便了用户的使用。目前, Siri 已经支持包括中文在内的 20 种不同语言。与 Siri 类似, 谷歌也在安卓 (Android) 系统上推出了谷歌语音搜索 (Google Voice Search)。另外一个成功应用语音识别的系统是微软的同声传译系统。在 2012 年的微软亚洲研究院 (Microsoft Research Asia, MSRA) 二十一世纪计算大会 (21st Century Computing) 上, 微软高级副总裁 Richard Rashid 现场演示了微软开发的从英语到汉语的同声传译系统^②。该演讲受到了非常广泛的关注, 在 YouTube 网站上已经有超过一百万次的播放量。同声传译系统不仅要求计算机能够对输入的语音进行识别, 它还要求计算机将识别出来的结果翻译成另外一门语言, 并将翻译好的结果通过语音合成的方式输出。在没有深度学习之前, 要完成同声传译系统中的任意一个部分都是非常困难的。而随着深度学习的发展, 语音识别、机器翻译以及语音合成都实现了巨大的技术突破。如今, 微软研发的同声传译系统已经被成功地应用到了 Skype 网络电话中。

1.3.3 自然语言处理

深度学习在自然语言处理领域的应用也同样广泛。在过去的几年中, 深度学习已经在

① 参见: Li D. *Achievements and Challenges of Deep Learning* [J]. *Apsipa Transactions on Signal & Information Processing*, 2015.

② 演讲视频地址为 http://v.youku.com/v_show/id_XNDcyOTUwNjMy.html。

语言模型 (language modeling)、机器翻译、词性标注 (part-of-speech tagging)、实体识别 (named entity recognition, NER)、情感分析 (sentiment analysis)、广告推荐以及搜索排序等方向上取得了突出成就。与深度学习在计算机视觉和语音识别等领域的突破类似,深度学习在自然语言处理问题上的突破也是能够更加智能、自动地提取复杂特征。在自然语言处理领域,使用深度学习实现智能特征提取的一个非常重要的技术是单词向量 (word embedding)。单词向量是深度学习解决很多上述自然语言处理问题的基础^{①②}。

在自然语言处理领域,一个非常棘手的问题在于自然语言中有很多词表达了相近的意思,比如“狗”和“犬”就几乎表达了同样的意思。然而“狗”和“犬”的编码在计算机中可能差别很大,所以计算机就无法很好地理解自然语言所表达的语义。为了解决这个问题,研究人员人工建立了大量的语料库。通过这些语料库,可以大致刻画自然语言中单词之间的关系。在建立好的语料库中,WordNet^③、ConceptNet^④和FrameNet^⑤是其中影响力比较大的几个。然而语料库的建立需要花费很多人力物力,而且扩展能力有限。单词向量提供了一种更加灵活的方式来刻画单词的语义。

单词向量会将每一个单词表示成一个相对较低维度的向量(比如100维或200维)。对于语义相近的单词,其对应的单词向量在空间中的距离也应该接近。于是单词语义上的相似度可以通过空间中的距离来描述。单词向量不需要通过人工的方式设定,它可以从互联网上海量非标注文本中学习得到。使用斯坦福大学开源的GloVe^⑥单词向量可以得到与单词“frog(青蛙)”所对应的单词向量最相似的5个单词分别是“frogs(青蛙复数)”、“toad(蟾蜍)”、“litoria(雨滨蛙属)”、“leptodactylidae(细趾蟾科)”和“rana(中国林蛙)”。从这个样例可以看出,单词向量可以非常有效地刻画单词的语义。通过单词向量还可以进行单词之间的运算。比如用单词“king”所代表的向量减去单词“man”所代表的向量得到的结果向量和单词“queen”减去“woman”得到的结果向量相似。这说明在单词向量中,已经隐含了表达性别概念。

- ① 参见: Mikolov T, Sutskever I, Chen K, et al. *Distributed Representations of Words and Phrases and their Compositionality* [J]. *Advances in Neural Information Processing Systems*, 2013, 26..
- ② 参见: Collobert R, Weston J, Bottou L, et al. *Natural Language Processing (Almost) from Scratch* [J]. *Journal of Machine Learning Research*, 2011.
- ③ 更多关于 WordNet 的资料可以参考其官方网站: <https://wordnet.princeton.edu/>。
- ④ 更多关于 ConceptNet 的资料可以参考其官方网站: <http://conceptnet5.media.mit.edu/>。
- ⑤ 更多关于 FrameNet 的资料可以参考其官方网站: <https://framenet.icsi.berkeley.edu/fndrupal/>。
- ⑥ 具体关于 GloVe 的介绍可以参考其官方网站: <http://nlp.stanford.edu/projects/glove/>。

通过对自然语言中单词更好地抽象与表达，深度学习在自然语言处理的很多核心问题上都有突破性的进展。机器翻译就是其中的一个例子。图 1-10 展示了谷歌翻译提供的传统算法和深度学习算法翻译不同语言对的质量对比图。从图 1-10 可以看出，在所有的语言对上，深度学习算法都可以大幅度提高翻译的质量。根据谷歌的实验结果，在主要的语言对上，使用深度学习可以将机器翻译算法的质量提高 55%到 85%。表 1-1 对比了不同算法翻译同一句话的结果。从表中可以直观地看到深度学习算法带来翻译质量的提高。在 2016 年 9 月，谷歌正式上线了基于深度学习的中译英软件。现在在谷歌翻译产品中，已经有 8 种语言是由基于深度学习的翻译算法完成的。




图 1-10 不同翻译算法在不同语言上的翻译质量^①（其中 0 表示最低的质量，6 表示最好的质量）

表 1-1 不同翻译算法的翻译效果对比表^②

中文原句	李克强此行将启动中加总理年度对话机制，与加拿大总理杜鲁多举行两国总理首次年度对话。
基于传统机器学习算法的翻译结果	Li Keqiang premier added this line to start the annual dialogue mechanism with the Canadian Prime Minister Trudeau two prime ministers held its first annual session.
基于深度学习算法的翻译结果	Li Keqiang will start the annual dialogue mechanism with Prime Minister Trudeau of Canada and hold the first annual dialogue between the two premiers.
人工翻译结果	Li Keqiang will initiate the annual dialogue mechanism between premiers of China and Canada during this visit, and hold the first annual dialogue with Premier Trudeau of Canada.

① 数字出自谷歌技术博客：<https://research.googleblog.com/2016/09/a-neural-network-for-machine.html>。

② 此表中数据出自谷歌技术博客：<https://research.googleblog.com/2016/09/a-neural-network-for-machine.html>。

情感分析是自然语言处理问题中另外一个非常经典的应用。情感分析最核心的问题就是从一段自然语言中判断作者对评价的主体是好评还是差评。情感分析在工业界有着非常广泛的应用。随着互联网的发展,用户会在各种不同的地方表达对于不同产品的看法。对于服务行业或者制造业,及时掌握用户对其产品或者服务的评价是提高用户满意度非常有效的途径。在金融行业,通过分析用户对不同产品和公司的态度可以对投资选择提供帮助。Derwent Capital Markets 于 2012 年 5 月正式上线,它是世界首家通过对社交网络 Twitter 上推文进行情感分析来指导证券交易^①的对冲基金公司。在同年 8 月的一份调查中显示,该公司的平均收益率 1.85% 远远超过了平均 0.76% 的收益率。类似的,也有研究表明,在政治选举中,通过对 Twitter 上推文情感分析得出的结果和通过传统的调查、投票等方法得出的结果高度一致^②。在情感分析问题上,深度学习也可以大幅提高算法的准确率。在斯坦福大学开源的 Sentiment Treebank 数据集上^③,使用深度学习的算法可以将语句层面的情感分析正确率从 80% 提高到 85.4%。在短语层面上,使用深度学习的算法可以将正确率从 71% 提高到 80.7%^④。

1.3.4 人机博弈

如果说深度学习在图像识别领域上的突破掀起了学术界的研究浪潮,那么深度学习在人机博弈上的突破使得这个概念被全社会所熟悉。在北京时间 2016 年 3 月 15 日的下午,谷歌开发的围棋人工智能系统 AlphaGo 以总比分 4:1 战胜了韩国棋手李世石,成为第一个在 19×19 棋盘上战胜人类围棋冠军的智能系统。虽然 AlphaGo 不是第一个战胜人类世界冠军的系统,但 AlphaGo 的胜利绝对是人工智能历史上的一座里程碑。在 1997 年 IBM 的智能国际象棋系统深蓝 (deep blue) 击败世界冠军卡斯帕罗夫时,所依赖的更多是计算机的计算资源,是通过暴力搜索 (brute-force) 的方式尝试更多的下棋方法从而战胜人类。然

① 参见: Bollen J, Mao H, Zeng X. *Twitter mood predicts the stock market* [J]. *Journal of Computational Science*, 2010.

② 参见: O'Connor B, Balasubramanyan R, Routledge B R, et al. *From Tweets to Polls: Linking Text Sentiment to Public Opinion Time Series* [C]// International Conference on Weblogs and Social Media, ICWSM 2010, Washington, Dc, Usa, May. DBLP, 2010.

③ <http://nlp.stanford.edu/sentiment/>中给出了更多关于 Sentiment Treebank 的信息。

④ Socher R, Perelygin A, Wu J Y, et al. Recursive deep models for semantic compositionality over a sentiment treebank[J]. 2013.

而这种方式在围棋上是完全不适用的，因为搜索围棋下子方法的复杂度为 10^{172} ，而国际象棋只有 10^{46} 。

为了战胜人类围棋世界冠军，AlphaGo 需要使用更加智能的方式。深度学习技术为这种方式提供了可能。AlphaGo 主要是由三个部分组成，他们分别是蒙特卡罗树搜索（Monte Carlo tree search, MCTS）、估值网络（value network）和走棋网络（policy network）。蒙特卡罗树搜索算法实现了对不同落子点的搜索，不过和之前的纯暴力搜索不同，AlphaGo 中使用的蒙特卡罗树会根据估值网络和走棋网络对落子后局势的评判结果来更加智能地寻找最佳落子点。

AlphaGo 背后真正的大脑是估值网络和走棋网络，而这两个组件都是通过深度学习实现的。走棋网络解决的问题是给定当前棋盘，预测下一步应该在哪落子。通过在大量人类围棋高手对弈的棋谱获取的训练数据，走棋网络能够以 57% 的准确率预测人类围棋高手下一步的落子点。然而，仅仅预测人类高手的落子方法是不够的，为了能够战胜人类冠军，走棋网络还通过自己跟自己对弈的方式来进一步提高落子水平。AlphaGo 的另外一个大脑是估值网络，它解决的问题是给定当前的棋盘，判断黑棋赢的概率。训练估值网络所使用的数据就是落子网络自己和自己对弈时产生的。通过蒙特卡罗树搜索的方法将走棋网络和估值网络这两个大脑有机地结合，AlphaGo 才最终以悬殊的比分战胜了人类的围棋世界冠军。

AlphaGo 战胜人类世界冠军不是人机博弈的终点，相反，这只是一个开始。AlphaGo 的开发团队 DeepMind 最近又宣布了他们的下一个目标——星际争霸 2^①。星际争霸 2 是暴雪公司（Blizzard）开发的一款即时战略游戏。在游戏中，玩家需要采集资源、建造建筑、生产战斗单位来消灭对方玩家。相比围棋，星际争霸 2 对于人工智能系统设计的难度又有指数级的提高。首先，围棋的落子方式虽然多，但也是有限的。而人工智能操作星际争霸 2 时，在任意一个时刻，人工智能系统需要同时（几乎同时）操作多个不同单位，而且操作的方式是完全开放的，几乎没有限制，所以确定这些操作很难通过搜索完成。其次，星际争霸 2 是一个信息不对称的系统。下围棋时对弈双方看到的棋盘都是一样的，而星际争霸 2 中每个玩家只能看到自己的地盘，这要求人工智能系统对“局势”做出判断。第三，星际争霸 2 是即时对战游戏，需要计算机在很短的时间内做出判断，这对人工智能系统的计算速度有很高的要求。如今暴雪公司已经正式开始了与 DeepMind 团队的合作，并将在不久之后开放专门为人工智能研究设计的星际争霸 2 的 API。在星际争霸 2 上，人工智能何时能战胜人类，我们将拭目以待。

^① 具体报道参见：<https://deepmind.com/blog/deepmind-and-blizzard-release-starcraft-ii-ai-research-environment/>。

1.4 深度学习工具介绍和对比

在上面的章节中已经介绍了深度学习的概念以及历史，并给出了不少成功应用深度学习的样例。然而，要将深度学习更快且更便捷地应用于新的问题中，选择一款深度学习工具是必不可少的步骤。这一节将介绍深度学习工具 TensorFlow 的主要功能和特点，并将对比 TensorFlow 和其他主流的开源深度学习工具，给出本书选择 TensorFlow 作为主要介绍对象的依据。TensorFlow 是谷歌于 2015 年 11 月 9 日正式开源的计算框架。TensorFlow 计算框架可以很好地支持深度学习的各种算法，但它的应用也不限于深度学习。因为本书的重点是介绍使用 TensorFlow 实现深度学习算法，所以本书中将略去 TensorFlow 对于其他算法的支持，感兴趣的读者可以在 TensorFlow 的官方教程 <https://www.tensorflow.org/tutorials> 上找到更多通过 TensorFlow 实现非深度学习算法的样例。

TensorFlow 是由 Jeff Dean 领头的谷歌大脑团队基于谷歌内部第一代深度学习系统 DistBelief 改进而来的通用计算框架。DistBelief 是谷歌 2011 年开发的内部深度学习工具，这个工具在谷歌内部已经获得了巨大的成功。基于 DistBelief 的 ImageNet 图像分类系统 Inception 模型赢得了 ImageNet2014 年的比赛 (ILSVRC)^①。通过 DistBelief，谷歌在海量的非标注 YouTube 视屏中习得了“猫”的概念，并在谷歌图片中开创了图片搜索的功能。使用 DistBelief 训练的语音识别模型成功将语音识别的错误率降低了 25%。在一次 BBC 采访中，当时的谷歌首席执行官 Eric Schmidt 表示这个提高比率相当于之前十年的总和^②。

虽然 DistBelief 已经被谷歌内部很多产品所使用，但是 DistBelief 过于依赖谷歌内部的系统架构，很难对外开源。为了将这样一个在谷歌内部已经获得了巨大成功的系统开源，谷歌大脑团队对 DistBelief 进行了改进，并于 2015 年 11 月正式公布了基于 Apache 2.0 开源协议的计算框架 TensorFlow。相比 DistBelief，TensorFlow 的计算模型更加通用、计算速度更快、支持的计算平台更多、支持的深度学习算法更广而且系统的稳定性也更高。在本书后面的章节中，我们将重点介绍 TensorFlow 的使用，关于 TensorFlow 平台本身的技术细节可以参考谷歌的论文 *TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems*^③。

① 在第 6 章中将具体介绍 ILSVRC 比赛以及 Inception 模型。

② 此数字来源于：<http://www.csmonitor.com/Technology/2015/0914/Google-chairman-We-re-making-real-progress-on-artificial-intelligence>。

③ 参见：Abadi M, Agarwal A, Barham P, et al. *TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems* [J]. 2016.

如今在谷歌内部，TensorFlow 已经得到了广泛的应用。在 2015 年 10 月 26 日，谷歌正式宣布通过 TensorFlow 实现的排序系统 RankBrain 上线。相比一些传统的排序算法，使用 RankBrain 的排序结果更能满足用户需求。在 2015 年彭博（Bloomberg）的报道中^①，谷歌透露了在谷歌上千种排序算法中，RankBrain 是第三重要的排序算法。基于 TensorFlow 的系统 RankBrain 能在谷歌的核心网页搜索业务中占据如此重要的地位，可见 TensorFlow 在谷歌内部的重要性。包括网页搜索在内，TensorFlow 已经被成功应用到了谷歌的各款产品之中。如今，在谷歌的语音搜索、广告、电商、图片、街景图、翻译、YouTube 等众多产品之中都可以看到基于 TensorFlow 的系统^②。在经过半年的尝试和思考之后，谷歌的 DeepMind 团队也正式宣布其之后所有的研究都将使用 TensorFlow^③作为实现深度学习算法的工具。

除了在谷歌内部大规模使用之外，TensorFlow 也受到了工业界和学术界的广泛关注。在 Google I/O 2016 的大会上，Jeff Dean 提到已经有 1500 多个 GitHub 的代码库中提到了 TensorFlow，而只有 5 个是谷歌官方提供的。如今，包括优步（Uber）、Snapchat、Twitter、京东、小米等国内外科技公司也纷纷加入了使用 TensorFlow 的行列。正如谷歌在 TensorFlow 开源原因中所提到的一样，TensorFlow 正在建立一个标准，使得学术界可以更方便地交流学术研究成果，工业界可以更快地将机器学习应用于生产之中。

除了 TensorFlow，目前还有一些主流的深度学习开源工具。表 1-2 中总结了这些工具的主要情况。每款工具都有各自的特点，由于篇幅所限，在本书中不再一一介绍每一个工具目前的优缺点，感兴趣的读者可以参考脚注中每种工具的官方网站给出的信息。

表 1-2 主流的深度学习开源工具总结表^④

工具名称	主要维护人员（或团体）	支持语言	支持系统
Caffe ^⑤	加州大学伯克利分校视觉与学习中心	C++、Python、MATLAB	Linux、Mac OS X、Windows
Deeplearning4j ^⑥	Skyminid	Java、Scala、Clojure	Linux、Windows、Mac OS X、Android

① 具体报道参见：<https://www.bloomberg.com/news/articles/2015-10-26/google-turning-its-lucrative-web-search-over-to-ai-machines>。

② TensorFlow 官方网站：<https://www.tensorflow.org/versions/r0.9/resources/uses.html> 上列出了一些使用 TensorFlow 的样例项目。

③ 具体报道参见谷歌官方技术博客：<https://research.googleblog.com/2016/04/deepmind-moves-to-tensorflow.html>。

④ 表中工具根据字母序排列。

⑤ Caffe 官方网站：<http://caffe.berkeleyvision.org/>。

⑥ Deeplearning4j 官方网站：<https://deeplearning4j.org/>。

续表

工具名称	主要维护人员（或团体）	支持语言	支持系统
Microsoft Cognitive Toolkit (CNTK) ①	微软研究院	Python、C++、BrainScript	Linux、Windows
MXNet ^②	分布式机器学习社区 (DMLC)	C++、Python、Julia、Matlab、Go、R、Scala	Linux、Mac OS X、Windows、Android、iOS
PaddlePaddle ^③	百度	C++、Python	Linux、Mac OS X
TensorFlow	谷歌	C++、Python	Linux、Mac OS X、Android、iOS
Theano ^④	蒙特利尔大学	Python	Linux、Mac OS X、Windows
Torch ^⑤	Ronan Collobert、Soumith Chintala (Facebook) Clement Farabet (Twitter) Koray Kavukcuoglu (Google)	Lua、LuaJIT、C	Linux、Mac OS X、Windows、Android、iOS

作者认为，不同的深度学习工具都在发展之中，比较当前的性能、功能固然是选择工具的一种方法，但更加重要的是比较不同工具的发展趋势。深度学习本身就是一个处于蓬勃发展阶段的领域，所以对深度学习工具的选择，作者认为应该更加看重工具在开源社区的活跃程度。只有社区活跃度更高的工具，才有可能跟上深度学习本身的发展速度，从而在未来不会面临被淘汰的风险。

图 1-11 对比了不同深度学习工具在 GitHub 上活跃程度的一些指标。图 1-11 (a) 中比较了不同工具在 GitHub 上受关注的程度。从图中可以看出，无论是在获得的星数 (star) 还是在仓库被复制的次数上，TensorFlow 都要远远超过其他的深度学习工具。如果说图 1-11(a) 只能代表不同深度学习工具在社区受关注程度，那么图 1-11(b) 对比了不同深度学习工具社区参与度。图 1-11(b) 中展示了不同深度学习工具在 GitHub 上最近一个月的活跃讨论贴和代码提交请求数量。活跃讨论贴越多，可以说明真正使用这个工具的人也就越多；提交代码请求数量越多，可以说明参与到开发这个工具的人也就越多。从图 1-11 (b) 中可以看出，无论从哪个指标，TensorFlow 都要远远超过其他深度学习工具。大量的活跃开发者再加上谷歌的全力支持，作者相信 TensorFlow 在未来将有更大的潜力，这也是本书将 TensorFlow 作为介绍对象的重要依据。

① Microsoft Cognitive Toolkit 官方网站: <https://www.microsoft.com/en-us/research/product/cognitive-toolkit/>。

② MXNet 官方网站: <http://mxnet.io/>。

③ PaddlePaddle 官方网站: <http://www.paddlepaddle.org/>。

④ Theano 官方网站: <http://deeplearning.net/software/theano/>。

⑤ Torch 官方网站: <http://torch.ch/>。



(a) 不同深度学习工具社区流行度指标比较^①(b) 同深度学习工具社区参与度指标比较^②

图 1-11 不同深度学习工具在 GitHub 上活跃程度对比图

小结

本章对深度学习做了全方位的介绍。首先 1.1 节介绍了人工智能、机器学习以及深度学习的概念，并解释了这些概念之间的差异。人工智能是一类非常广泛的问题，它旨在通过计算机实现类似人类的智能。机器学习是解决人工智能问题的一个重要方法。深度学习则是机器学习的一个分支，它在很多领域突破了传统机器学习的瓶颈，将人工智能推向了一个新的高潮。然而，这样一个突破性的技术并不是最近几年凭空创造的，它所基于的人

① 图中数据获取的时间为 2016 年 11 月 17 日。

② 图中数据来自于 Github 上 2016 年 10 月 15 日至 2016 年 11 月 15 日的统计数据。

工神经网络（artificial neural network, ANN）技术已经发展了大半个世纪。不过神经网络的发展不是一帆风顺，1.2 节完整的介绍了它发展的三个起落。

受到人类大脑结构的启发，人工神经网络的计算模型于 1943 年首次提出。之后感知机的发明使得人工神经网络成为真正可以从数据中“学习”的模型。但由于感知机的网络结构过于简单，导致无法解决线性不可分问题。再加上人工神经网络所需要的计算量太大，当时的计算机无法满足计算需求，使得人工神经网络的研究进入了第一个寒冬。到 20 世纪 80 年代，深层神经网络和反向传播算法的提出很好地解决了这些问题，让人工神经网络进入第二个快速发展期。不过，在这一时期中，以支持向量机为主的传统机器学习算法也在飞速发展。在 90 年代中期，在很多机器学习任务上，传统机器学习算法超越了人工神经网络的精确度，使得人工神经网络领域再次进入寒冬。直到 2012 年前后，随着云计算和海量数据的普及，人工神经网络以“深度学习”的名字再次进入大家的视野。在短短几年时间内，深度学习在很多研究领域突破了传统机器学习的瓶颈，推动了人工智能的发展。

人类大脑的结构分为了很多神经中枢，不同的神经中枢处理不同类型的输入。在很长一段时间，神经学家认为人类大脑不同的神经中枢有不同的处理逻辑。类似的，机器学习领域也一直分为计算机视觉、语音、自然语言处理等多个领域，而且不同领域使用的算法也有很大区别。然而，神经学家后来发现人类大脑不同神经中枢的学习算法是一致的。这使得人们看到了深度学习可以应用在多个领域的理论可能性。在实践中，深度学习也确实突破了很多领域的技术瓶颈。1.3 节介绍了深度学习在计算机视觉、语音、自然语言处理、人机博弈等多个领域上的突破性进展。在 ImageNet 图像分类的问题上，深度学习成功将错误率从 26%降低到了 3.5%。在语音识别问题上，谷歌通过深度学习将错误率降低了 25%，这一改进幅度是过去十年的总和。在自然语言处理上，基于深度学习的机器翻译、搜索排序、情感分析、自然语言建模等应用都已经在国内外各大科技公司内广泛使用。由谷歌 DeepMind 团队开发的围棋人机博弈系统 AlphaGo 更是激起了全社会对深度学习研究的热情。如今，深度学习已经渗透到了工业界和学术界的每一个领域。

要利用好深度学习所带来的福利，选择一款好的深度学习工具必不可少。1.4 节介绍了谷歌开源的深度学习工具 TensorFlow 的特性和在谷歌内部的应用，并将其和目前其他主流的开源深度学习工具做了比较。在谷歌内部，TensorFlow 已经被成功应用到语音搜索、广告、电商、图片、街景图、翻译、YouTube 等众多产品之中。基于 TensorFlow 开发的 RankBrain 排序算法在谷歌上千排序算法中排在第三重要的位置，由此可见 TensorFlow 在谷歌的重要地位。而且，对于 TensorFlow 的支持不仅仅来自谷歌。1.4 节对比了不同开源深度学习工具的社区活跃度。在各种指标上，TensorFlow 的活跃程度都要远远超过其他工具。所以，本书选择 TensorFlow 作为介绍的工具。在后面的章节中将具体介绍如何通过 TensorFlow 实现各种不同的深度学习算法，以及使用 TensorFlow 时的一些最佳实践。

第 2 章 TensorFlow 环境搭建

本章将介绍如何安装 TensorFlow 环境以及在安装好的环境中运行简单的 TensorFlow 样例程序。在介绍如何安装 TensorFlow 之前，2.1 节将首先介绍 TensorFlow 依赖的一些主要工具包。然后 2.2 节将介绍 TensorFlow 的不同安装方式以及这些安装方式所适用的不同的场景。最后 2.3 节将给出一个用 TensorFlow 完成向量加法的样例。通过这个样例程序，读者可以测试安装好的 TensorFlow 环境，同时也可以对 TensorFlow 有一个直观的认识。

2.1 TensorFlow 的主要依赖包

本节将介绍 TensorFlow 依赖的两个最主要的工具包——Protocol Buffer 和 Bazel。虽然 TensorFlow 依赖的工具包不仅限于此节中列出来的两个，但 Protocol Buffer 和 Bazel 是作者认为相对比较重要的，在使用 TensorFlow 的过程中很有可能会接触到。因为本书的重点是介绍 TensorFlow，所以在本节对列出来的工具包只进行大致的介绍，主要目的是为了不妨碍读者对 TensorFlow 的使用和理解。这些工具的详细介绍可以参考脚注。在以下的每个小节将介绍一个工具包的主要功能并给出简单的样例。

2.1.1 Protocol Buffer

Protocot Buffer^①是谷歌开发的处理结构化数据的工具。何为处理结构化数据？这里我们给出一个例子。假设要记录一些用户信息，每个用户的信息包括用户的名字、ID 和 E-mail 地址。那么一个用户的信息可以表示为以下的形式。

① <https://developers.google.com/protocol-buffers/docs/overview> 中给出了更多关于 Protocol Buffer 的介绍。

```
name: 张三
id: 12345
email: zhangsan@abc.com
```

上面的用户信息就是一个结构化的数据。注意本节中介绍的结构化数据和大数据中的结构化数据的概念不同，本节中介绍的结构化数据指的是拥有多种属性的数据。比如上述的用户信息中包含名字、ID 和 E-mail 地址 3 种不同属性，那么它就是一个结构化数据。当要将这些结构化的用户信息持久化或者进行网络传输时，就需要先将它们序列化。所谓序列化，是将结构化的数据变成数据流的格式，简单地说就是变为一个字符串。如何将结构化的数据序列化，并从序列化之后的数据流中还原出原来的结构化数据，统称为处理结构化数据，这就是 Protocol Buffer 解决的主要问题。

除 Protocol Buffer 之外，XML 和 JSON 是两种比较常用的结构化数据处理工具。比如将上面的用户信息使用 XML 格式表达，那么数据的格式为：

```
<user>
  <name>张三</name>
  <id>12345</id>
  <email>zhangsan@abc.com</email>
</user>
```

同样的数据，使用 JSON 的格式为：

```
{
  "name": "张三",
  "id": "12345",
  "email": "zhangsan@abc.com",
}
```

Protocol Buffer 格式的数据和 XML 或者 JSON 格式的数据有比较大的区别。首先，Protocol Buffer 序列化之后得到的数据不是可读的字符串，而是二进制流。其次，XML 或 JSON 格式的数据信息都包含在了序列化之后的数据中，不需要任何其他信息就能还原序列化之后的数据。但使用 Protocol Buffer 时需要先定义数据的格式（schema）^①。还原一个序列化之后的数据将需要使用到这个定义好的数据格式。以下代码给出了上述用户信息样例的数据格式定义文件。因为这样的差别，Protocol Buffer 序列化出来的数据要比 XML 格式的数据小 3 到 10 倍，解析时间要快 20 到 100 倍。

```
message user{
  optional string name = 1;
  required int32 id = 2;
```

① <https://developers.google.com/protocol-buffers/docs/encoding> 中给出了 Protocol Buffer 的具体编码方式。

```
repeated string email = 3;  
}
```

Protocol Buffer 定义数据格式的文件一般保存在 .proto 文件中。每一个 message 代表了一类结构化的数据，比如这里的用户信息。message 里面定义了每一个属性的类型和名字。Protocol Buffer 里属性的类型可以是像布尔型、整数型、实数型、字符型这样的基本类型，也可以是另外一个 message。这样大大增加了 Protocol Buffer 的灵活性。在 message 中，Protocol Buffer 也定义了一个属性是必须的（required）还是可选的（optional），或者是可重复的（repeated）。如果一个属性是必须的（required），那么所有这个 message 的实例都需要有这个属性^①；如果一个属性是可选的（optional），那么这个属性的取值可以为空；如果一个属性是可重复的（repeated），那么这个属性的取值可以是一个列表。还是以用户信息为例，所有用户都需要有 ID，所以 ID 这个属性是必须的；不是所有用户都填写了姓名，所以姓名这个属性是可选的；一个用户可能有多个 E-mail 地址，所以 E-mail 地址是可重复的。

Protocol Buffer 是 TensorFlow 系统中使用到的重要工具，TensorFlow 中的数据基本都是通过 Protocol Buffer 来组织的。在后面的章节中将看到 Protocol Buffer 是如何被使用的。分布式 TensorFlow 的通信协议 gRPC 也是以 Protocol Buffer 作为基础的。

2.1.2 Bazel

Bazel^②是从谷歌开源的自动化构建工具，谷歌内部绝大部分的应用都是通过它来编译的。相比传统的 Makefile、Ant 或者 Maven，Bazel 在速度、可伸缩性、灵活性以及对不同程序语言和平台的支持上都要更加出色。TensorFlow 本身以及谷歌给出的很多官方样例都是通过 Bazel 来编译的。这一小节将简单介绍 Bazel 是怎样工作的。

项目空间（workspace）是 Bazel 的一个基本概念^③。一个项目空间可以简单地理解为一个文件夹，在这个文件夹中包含了编译一个软件所需要的源代码以及输出编译结果的软连接（symbolic link）地址。一个项目空间内可以只包含一个应用（比如 TensorFlow），这种情况在 2.2.3 小节中将会用于从源码安装 TensorFlow。一个项目空间也可以包含多个应用。一个项目空间所对应的文件夹是这个项目的根目录，在这个根目录中需要有一个 WORKSPACE 文件，此文件定义了对外部资源的依赖关系。空文件也是一个合法的

① 在最新的 Protocol Buffer3 中已经不再支持 required 类型。

② <http://www.bazel.io> 中给出了关于 Bazel 的更多介绍。

③ <http://www.bazel.io/docs/be/workspace.html> 中给出了项目空间的完整文档和开发手册。

WORKSPACE 文件。

在一个项目空间内，Bazel 通过 BUILD 文件来找到需要编译的目标^①。BUILD 文件采用一种类似于 Python 的语法来指定每一个编译目标的输入、输出以及编译方式。与 Makefile 这种比较开放式的编译工具不同，Bazel 的编译方式是事先定义好的。因为 TensorFlow 主要使用 Python 语言，所以这里都以编译 Python 程序为例。Bazel 对 Python 支持的编译方式只有三种：py_binary、py_library 和 py_test^②。其中 py_binary 将 Python 程序编译为可执行文件，py_test 编译 Python 测试程序，py_library 将 Python 程序编译成库函数供其他 py_binary 或 py_test 调用。下面给出了一个简单的样例来说明 Bazel 是如何工作的。如下所示，在样例项目空间中有 4 个文件：WORKSPACE、BUILD、hello_main.py 和 hello_lib.py。

```
-rw-rw-r-- root root 208 BUILD
-rw-rw-r-- root root 48 hello_lib.py
-rw-rw-r-- root root 47 hello_main.py
-rw-rw-r-- root root 0 WORKSPACE
```

WORKSPACE 给出此项目的外部依赖关系。为了简单起见，这里使用一个空文件，标明这个项目没有对外部的依赖。hello_lib.py 完成打印“Hello World”的简单功能，它的代码如下：

```
def print_hello_world():
    print("Hello World")
```

hello_main.py 通过调用 hello_lib.py 中定义的函数来完成输出，它的代码如下：

```
import hello_lib
hello_lib.print_hello_world()
```

在 BUILD 文件中定义了两个编译目标：

```
py_library(
    name = "hello_lib",
    srcs = [
        "hello_lib.py",
    ]
)

py_binary(
    name = "hello_main",
    srcs = [
        "hello_main.py",
```

① <http://www.bazel.io/docs/be/overview.html> 中给出了 BUILD 文件的完整文档和开发手册。

② <http://www.bazel.io/docs/test-encyclopedia.html> 中给出了更多关于测试目标的介绍。


```

    ],
    deps = [
        ":hello_lib",
    ],
)

```

从这个样例中可以看出，BUILD 文件是由一系列编译目标组成的。定义编译目标的先后顺序不会影响编译的结果。在每一个编译目标的第一行要指定编译方式，在这个样例中就是 `py_library` 或者 `py_binary`。在每一个编译目标中的主体需要给出编译的具体信息。编译的具体信息是通过定义 `name`, `srcs`, `deps` 等属性完成的。`name` 是一个编译目标的名字，这个名字将被用来指代这一条编译目标。`srcs` 给出了编译所需要的源代码，这一项可以是一个列表。`deps` 给出了编译所需要的依赖关系，比如样例中 `hello_main.py` 需要调用 `hello_lib.py` 中的函数，所以 `hello_main` 的编译目标中将 `hello_lib` 作为依赖关系。在这个项目空间中运行编译操作 `bazel build :hello_main` 将得到类似以下的结果：

```

lrwxrwxrwx 1 root root 74 bazel-bazel->~/cache/bazel/_bazel_root/0a1e386d667563a2d9ed561a4f7d1a3e/bazel/
lrwxrwxrwx 1 root root 104 bazel-bin->~/cache/bazel/_bazel_root/0a1e386d667563a2d9ed561a4f7d1a3e/bazel/bazel-out/local-fastbuild/bin/
lrwxrwxrwx 1 root root 109 bazel-genfiles->~/cache/bazel/_bazel_root/0a1e386d667563a2d9ed561a4f7d1a3e/bazel/bazel-out/local-fastbuild/genfiles/
lrwxrwxrwx 1 root root 84 bazel-out->~/cache/bazel/_bazel_root/0a1e386d667563a2d9ed561a4f7d1a3e/bazel/bazel-out/
lrwxrwxrwx 1 root root 109 bazel-testlogs->~/cache/bazel/_bazel_root/0a1e386d667563a2d9ed561a4f7d1a3e/bazel/bazel-out/local-fastbuild/testlogs/
-rw-rw-r-- 1 root root 208 BUILD
-rw-rw-r-- 1 root root 48 hello_lib.py
-rw-rw-r-- 1 root root 47 hello_main.py
-rw-rw-r-- 1 root root 0 WORKSPACE

```

从上面的结果可以看到，在原来 4 个文件的基础上，Bazel 生成了其他一些文件夹。这些新生成的文件夹就是编译的结果，它们都是通过软连接的形式放在当前的项目空间里。实际的编译结果文件都会保存到 `~/cache/bazel` 目录下，这是可以通过 `output_user_root` 或者 `output_base` 参数来改变的^①。在这些编译出来的结果当中，`bazel-bin` 目录下存放了编译产生的二进制文件以及运行该二进制文件所需要的所有依赖关系。在当前目录下运行 `bazel-bin/hello_main` 就会在屏幕输出“Hello World”。其他编译结果在本书中使用较少，这里就不再赘述。

2.2 TensorFlow 安装

TensorFlow 提供了多种不同的安装方式，本小节将逐一介绍通过 Docker 安装、通过 pip 安装以及从源码安装。

① http://www.bazel.io/docs/output_directories.html 中详细介绍了编译结果的目录结构。

2.2.1 使用 Docker 安装

Docker^①是新一代的虚拟化技术，它可以将 TensorFlow 以及 TensorFlow 的所有依赖关系封装到 Docker 镜像当中，从而大大简化了安装过程。通过 Docker 运行应用时需要先安装 Docker。Docker 支持大部分的操作系统，下面列出了最主要的一些。

- Linux 系统：Ubuntu、CentOS、Debian、红帽企业版（Red Hat Enterprise Linux）等。
- Mac OS X：10.10.3 Yosemite 或以上。
- Windows：Windows 7 或以上。

如何安装/使用 Docker 不是本书重点，这里就不再介绍在不同操作系统下如何安装 Docker^②。当 Docker 安装完成后，只需要使用一个打包好的 Docker 镜像。对于 TensorFlow 发布的每一个版本，谷歌都提供了 4 个官方镜像。表 2-1 给出了这些镜像的名称以及镜像中的包含的内容。

表 2-1 TensorFlow 官方 Docker 镜像列表

镜像名称	是否支持 GPU	是否含有源码
tensorflow/tensorflow:0.9.0	否	否
tensorflow/tensorflow:0.9.0-devel	否	是
tensorflow/tensorflow:0.9.0-gpu	是	否
tensorflow/tensorflow:0.9.0-devel-gpu	是	是

镜像的标签（冒号后面的部分）给出了 TensorFlow 的版本。本书的绝大部分代码将统一使用版本 0.9.0^③。才云科技也提供了 TensorFlow 的相关镜像 cargo.caicloud.io/tensorflow/tensorflow:0.12.0^④。与官方镜像类似，0.12.0 表示 TensorFlow 版本。如果 TensorFlow 推出更新的版本，此版本号可以被替换为更新的版本号。在官方镜像的基础上，才云科技提供的镜像进一步整合了其他机器学习工具包以及 TensorFlow 可视化工具 TensorBoard^⑤，使用起来可以更加方便。才云科技即将上线 TensorFlow 的公有云平台 caicloud.io，在此平台上可以直接运行 TensorFlow 程序，从而省去了安装的过程。

① <https://www.docker.com/what-docker> 中详细介绍了 Docker 的基本概念。

② <https://docs.docker.com/engine/installation> 中介绍了在不同操作系统下如何安装 Docker。

③ 因为 0.9.0 对循环神经网络支持不是特别友好，所以第 8 章部分代码使用了版本 0.10.0。在本书中，使用了其他版本的样例代码都给出了明确的注释。

④ 才云科技只提供 0.12.0 及以上版本的 TensorFlow 镜像。

⑤ 第 9 章将更加详细地介绍如何使用 TensorFlow 可视化工具 TensorBoard。

当 Docker 安装完成之后,可以通过以下命令来启动一个 TensorFlow 容器^①。在第一次运行的时候, Docker 会自动下载镜像。

```
$ docker run -it -p 8888:8888 -p 6006:6006 \
cargo.caicloud.io/tensorflow/ tensorflow:0.12.0
```

在这个命令中, `-p 8888:8888` 将容器内运行的 Jupyter[®] 服务映射到本地机器, 这样在浏览器中打开 `localhost:8888` 就能看到类似下图的 Jupyter 界面。在此镜像中运行的 Jupyter 是一个网页版的代码编辑器, 它支持创建、上传、修改和运行 Python 程序。通过 Jupyter, 才云科技提供了本书所有的样例程序, 如图 2-1 所示。




图 2-1 才云科技提供的 TensorFlow 镜像 Jupyter 页面示意图

`-p 6006:6006` 将容器内运行的 TensorFlow 可视化工具 TensorBoard 映射到本地机器, 通过在浏览器中打开 `localhost:6006` 就可以将 TensorFlow 在训练时的状态、图片数据以及神经网络结构等信息全部展示出来。此镜像会将所有输出到 `/log` 目录底下的日志全部可视化。具体如何使用 TensorBoard 将在第 9 章中详细介绍。

虽然支持 GPU 的 Docker 镜像, 但是要运行这些镜像需要安装最新的 Nvidia 驱动以及 `nvidia-docker`^③。在安装完成 `nvidia-docker` 之后, 可以通过以下的命令运行支持 GPU 的 TensorFlow 镜像。在镜像启动之后可以通过和上面类似的方式使用 TensorFlow。

```
$ nvidia-docker run -it -p 8888:8888 -p 6006:6006 \
cargo.caicloud.io/tensorflow/tensorflow:0.12.0-gpu
```

① <https://docs.docker.com/engine/reference/commandline/cli> 中给出了 Docker 命令的文档。

② <http://jupyter.org/> 中给出了对 Jupyter 更加详细的介绍。

③ <https://github.com/NVIDIA/nvidia-docker> 中介绍了 `nvidia-docker` 的基本原理和安装说明。

2.2.2 使用 pip 安装

pip 是一个安装、管理 Python 软件包的工具^①，通过 pip 可以安装已经打包好的 TensorFlow 以及 TensorFlow 所需要的依赖关系。目前 TensorFlow 只提供了部分操作系统下打包好的安装文件，在其他操作系统下安装或者需要安装定制化代码的 TensorFlow 请参考 2.2.3 小节。通过 pip 安装可以分为以下三步。

第一步：安装 pip

```
# 在 Ubuntu/Linux 64-bit 环境下安装。
$ sudo apt-get install python-pip python-dev

# 在 Mac OS X 环境下安装。
$ sudo easy_install pip
$ sudo easy_install --upgrade six
```

第二步：找到合适的安装包 URL

仅支持 CPU 的 TensorFlow 安装包有：

```
# Ubuntu/Linux 64-bit, Python 2.7 环境。
$ export TF_BINARY_URL=https://storage.googleapis.com/tensorflow/linux/
cpu/tensorflow-0.9.0-cp27-none-linux_x86_64.whl

# Ubuntu/Linux 64-bit, Python 3.4 环境。
$ export TF_BINARY_URL=https://storage.googleapis.com/tensorflow/linux/
cpu/tensorflow-0.9.0-cp34-cp34m-linux_x86_64.whl

# Ubuntu/Linux 64-bit, CPU only, Python 3.5 环境。
$ export TF_BINARY_URL=https://storage.googleapis.com/tensorflow/linux/
cpu/tensorflow-0.9.0-cp35-cp35m-linux_x86_64.whl

# Mac OS X, Python 2.7 环境。
$ export TF_BINARY_URL=https://storage.googleapis.com/tensorflow/mac/
tensorflow-0.9.0-py2-none-any.whl

# Mac OS X, Python 3.4 or 3.5 环境。
$ export TF_BINARY_URL=https://storage.googleapis.com/tensorflow/mac/
tensorflow-0.9.0-py3-none-any.whl
```

目前只有在安装了 CUDA toolkit 7.5 和 CuDNN v4 的 64 位 Ubuntu 下可以通过 pip 安装

^① <https://pip.pypa.io> 中给出 pip 的文档。

支持 GPU 的 TensorFlow, 对于其他系统或者其他 CUDA/CuDNN 版本的用户, 则需要从源码进行安装来支持 GPU 使用。如何从源码进行安装将在 2.2.3 小节中详述。下面给出了支持 GPU 的 TensorFlow pip 安装包的 URL:

```
# Python 2.7 环境
$ export TF_BINARY_URL=https://storage.googleapis.com/tensorflow/linux/gpu/tensorflow-0.9.0-cp27-none-linux_x86_64.whl

# Python 3.4 环境
$ export TF_BINARY_URL=https://storage.googleapis.com/tensorflow/linux/gpu/tensorflow-0.9.0-cp34-cp34m-linux_x86_64.whl

# Python 3.5 环境
$ export TF_BINARY_URL=https://storage.googleapis.com/tensorflow/linux/gpu/tensorflow-0.9.0-cp35-cp35m-linux_x86_64.whl
```

第三步: 通过 pip 安装 TensorFlow

```
# Python 2 环境
$ sudo pip install --upgrade $TF_BINARY_URL

# Python 3 环境
$ sudo pip3 install --upgrade $TF_BINARY_URL
```

通过这三步, TensorFlow 环境就安装完成了。

2.2.3 从源代码编译安装

从源代码安装 TensorFlow 的过程主要就是将 TensorFlow 源代码编译成 pip 安装包的过程。将 TensorFlow 的源代码编译为 pip 所使用的 wheel 文件之后, 通过 2.2.2 小节中介绍的 pip install 的方法就可以完成安装。在编译 TensorFlow 源代码之前需要先安装 TensorFlow 所依赖的其他工具包。不同操作系统下需要安装的工具包略微有一些差别, 而且在不同操作系统下安装这些工具包的方法也不大一样, 这一小节将以 Ubuntu 14.04 和 Mac OS X 为例来介绍如何安装 TensorFlow 依赖的工具包^①。

在 Ubuntu 14.04 下安装依赖的工具包

首先需要安装 2.1.2 小节中介绍的编译工具 Bazel。安装 Bazel, 首先要安装 JDK8。以

① 其他版本的 Linux 可以参考 Ubuntu 14.04 下的安装方法。目前 TensorFlow 没有比较好的支持在 Windows 下从源码安装, Windows 用户可以通过 2.2.1 节中介绍的 Docker 来使用 TensorFlow。

下代码给出了安装 JDK8 的方法。

```
$ sudo apt-get install software-properties-common
$ sudo add-apt-repository ppa:webupd8team/java
$ sudo apt-get update
$ sudo apt-get install oracle-java8-installer
```

然后安装 Bazel 的其他依赖的工具包：

```
$ sudo apt-get install pkg-config zip g++ zlib1g-dev unzip
```

接着在 Bazel 的 GitHub 发布页面下载安装包 (<https://github.com/bazelbuild/bazel/releases/tag/0.3.1>)。其中 0.3.1 为 Bazel 的版本号。如果有更新的版本，可以相应的替换上面连接中的版本号。在这个页面中下载安装包 `bazel-0.3.1-jdk7-installer-linux-x86_64.sh`，然后就可以通过这个安装包来安装 Bazel。以下代码实现了 Bazel 的安装过程。

```
$ chmod +x bazel-0.3.1-jdk7-installer-linux-x86_64.sh
$ ./bazel-0.3.1-jdk7-installer-linux-x86_64.sh -user
$ export PATH="$PATH:$HOME/bin"
```

Bazel 安装完成后还需要通过以下代码来安装 TensorFlow 的依赖的其他工具包。

```
# Python 2.7 环境
$ sudo apt-get install python-numpy swig python-dev python-wheel

# Python 3.x 环境
$ sudo apt-get install python3-numpy swig python3-dev python3-wheel
```

如果要支持 GPU，那么还需要安装 Nvidia 的 Cuda Toolkit（版本需要大于或等于 7.0）和 cuDNN（版本需要大于或等于 v2）。而且 TensorFlow 只支持 Nvidia 计算能力（compute capability）大于 3.0 的 GPU。比如 Nvidia Titan、Nvidia Titan X、Nvidia K20、Nvidia K40 等都满足要求^①。

Cuda Toolkit 的安装包以及安装方法可登录 <https://developer.nvidia.com/cuda-downloads> 获得。在根据引导填写完操作系统相关参数之后，该网站将提供 Cuda 7.5 的安装包及详细安装方法。登录 <https://developer.nvidia.com/cudnn> 可下载 cuDNN 的安装包。在下载之前需要先注册，但注册是完全免费的。注册完成后可以下载 cuDNN v4 Library for Linux，其中 v4 可以替换成更新的版本。下载完成后，需要通过以下命令把下载下来的安装包复制到 Cuda 的目录（这里假设是 `/usr/local/cuda`）：

```
tar xvfz cudnn-7.5-linux-x64-v4.tgz
sudo cp cudnn-7.5-linux-x64-v4/cudnn.h /usr/local/cuda/include
```

① <https://developer.nvidia.com/cuda-gpus> 中列出了所有 GPU 的计算能力。


```
sudo cp cudnn-7.5-linux-x64-v4/libcudnn* /usr/local/cuda/lib64
sudo chmod a+r /usr/local/cuda/include/cudnn.h \
/usr/local/cuda/lib64/libcudnn*
```

在 Mac OS X 下安装依赖工具包

Homebrew 是 Mac OS X 下一个软件安装工具^①，通过这个工具可以很方便地安装比如 Bazel, SWIG 等 TensorFlow 的依赖工具。Homebrew 自己的安装过程也很简单，以下代码给出了它的安装方法：

```
/usr/bin/ruby -e "$(curl -fsSL \
https://raw.githubusercontent.com/Homebrew/install/master/install)"
```

安装完 Homebrew 后就可以通过 brew 来安装 Bazel 和 SWIG：

```
$ brew install bazel swig
```

然后可以通过 easy_install 来安装 Python 相关的依赖工具：

```
$ sudo easy_install -U six
$ sudo easy_install -U numpy
$ sudo easy_install wheel
$ sudo easy_install ipython
```

如果需要在 GPU 上运行，在安装 Cuda Toolkit 和 cuDNN 之前，还需要通过 Homebrew 安装 GNU coreutils：

```
$ brew install coreutils
```

和 Ubuntu 14.04 类似，<https://developer.nvidia.com/cuda-downloads> 网站提供了安装最新 Cuda Toolkit 的安装包与安装方法。但在 Mac OS X 下可以通过 Homebrew Cask 来直接安装：

```
$ brew tap caskroom/cask
$ brew cask install cuda
```

Cuda Toolkit 安装完成之后需要将环境变量加入到 ~/.bash_profile 文件中：

```
export CUDA_HOME=/usr/local/cuda
export DYLD_LIBRARY_PATH="$DYLD_LIBRARY_PATH:$CUDA_HOME/lib"
export PATH="$CUDA_HOME/bin:$PATH"
```

<https://developer.nvidia.com/cudnn> 网站提供了 cuDNN 的安装包。在下载之前这个网站需要先注册，注册是完全免费的。注册完成后可以下载 cuDNN v4 Library for OS X，其中 v4 可以替换成更新的版本。下载完成后需要将文件解压并放到 Cuda Toolkit 的目录下。以

^① <http://brew.sh> 中介绍 Homebrew 的功能。

下代码完成了这个过程：

```
$ sudo mv include/cudnn.h /Developer/NVIDIA/CUDA-7.5/include/
$ sudo mv lib/libcudnn* /Developer/NVIDIA/CUDA-7.5/lib
$ sudo ln -s /Developer/NVIDIA/CUDA-7.5/lib/libcudnn* /usr/local/cuda/lib/
```

配置 TensorFlow 编译环境

在所有依赖的工具包都安装完成之后就可以开始从源码来安装 TensorFlow 了。无论在哪个操作系统下，要从源代码开始安装，首先需要下载源代码。通过以下命令可以下载最新的 TensorFlow 源代码：

```
$ git clone https://github.com/tensorflow/tensorflow
```

使用以上命令将下载 TensorFlow 最新的代码。如果需要下载之前发布的版本，可以在上述命令中加入 `-b <branchname>` 参数。其中 `<branchname>` 可以是 `r0.7`、`r0.8`、`r0.9` 等。如果安装 `r0.8` 或者更老的版本，还需要在上述命令中加入 `--recurse-submodules` 参数来拉取 TensorFlow 依赖的其他工具。源码下载完成之后，需要运行 `configure` 脚本来配置环境信息：

```
$ cd tensorflow
$ ./configure
# 配置 Python 的路径。
Please specify the location of python. [Default is /usr/bin/python]:
# 配置是否支持谷歌云平台。
Do you wish to build TensorFlow with Google Cloud Platform support? [y/N]N
No Google Cloud Platform support will be enabled for TensorFlow
# 配置是否支持 GPU。
Do you wish to build TensorFlow with GPU support? [y/N] y
GPU support will be enabled for TensorFlow
# 配置 GPU。
Please specify which gcc nvcc should use as the host compiler. [Default is /usr/bin/gcc]:
# 配置 Cuda SDK 版本。
Please specify the Cuda SDK version you want to use, e.g. 7.0. [Leave empty to use system default]: 7.5
# 配置 CUDA toolkit 目录。
Please specify the location where CUDA 7.5 toolkit is installed. Refer to README.md for more details. [Default is /usr/local/cuda]:
# 配置 Cudnn 版本。
Please specify the Cudnn version you want to use. [Leave empty to use system default]: 4
# 配置 cuDNN 目录。
Please specify the location where cuDNN 4 library is installed. Refer to README.md for more details. [Default is /usr/local/cuda]:
```

```
# 配置 GPU 计算能力。
Please specify a list of comma-separated Cuda compute capabilities you want
to build with.
You can find the compute capability of your device at: https://developer.
nvidia.com/cuda-gpus.
Please note that each additional compute capability significantly increases
your build time and binary size.

Setting up Cuda include
Setting up Cuda lib
Setting up Cuda bin
Setting up Cuda nvvm
Setting up CUPTI include
Setting up CUPTI lib64
Configuration finished
```

当环境配置完成之后通过 Bazel 来编译 pip 的安装包，然后通过 pip 安装：

```
$ bazel build -c opt --config=cuda \
    //tensorflow/tools/pip_package:build_pip_package
$ bazel-bin/tensorflow/tools/pip_package/build_pip_package \
    /tmp/tensorflow_pkg
$ sudo pip install /tmp/tensorflow_pkg/tensorflow-0.9.0-py2-none-any.whl
```

第一个命令中--config=cuda 参数为对 GPU 的支持。如果不需要支持 GPU，就不需要这个参数了。最后一行中 wheel 安装包的名字 (tensorflow-0.9.0-py2-none-any.whl) 和系统环境有关，使用 pip 安装之前可以先通过 ls 命令来确认安装包的名字。

2.3 TensorFlow 测试样例

通过 2.2 节中介绍的方法安装好 TensorFlow 后，在这一节中将给出一个简单的 TensorFlow 样例程序来实现两个向量求和。TensorFlow 支持 C、C++ 和 Python 三种语言，但是它对 Python 的支持是最全面的，所以本书中所有的样例都会使用 Python 语言。通过本节给出来的简单样例，读者可以测试安装好的 TensorFlow 环境，同时也可以对 TensorFlow 有一个直观的认识。这一节将直接使用 Python 自带的交互界面来演示这个简单样例：

```
# python
Python 2.7.6 (default, Jun 22 2015, 17:58:13)
[GCC 4.8.2] on linux2
Type "help", "copyright", "credits" or "license" for more information.
>>>
```

在进入 Python 交互界面之后，先通过 import 操作加载 TensorFlow：

```
>>> import tensorflow as tf
```

上图显示 TensorFlow 已经成功加载了。Python 可以通过重命名来使引用更加方便，在本书中都会将“tensorflow”简写为“tf”。然后定义两个向量，a 和 b：

```
>>> a = tf.constant([1.0, 2.0], name="a")
>>> b = tf.constant([2.0, 3.0], name="b")
```

在这里将 a 和 b 定义为了两个常量（tf.constant），一个为[1.0,2.0]，另一个为[2.0,3.0]。在两个加数定义好之后，将这两个向量加起来：

```
>>> result = a + b
```

熟悉 NumPy^①的读者会发现，在 TensorFlow 之中，向量的加法也是可以直接通过加号（+）来完成的。最后输出相加得到的结果：

```
>>> sess = tf.Session()
>>> sess.run(result)
array([ 3.,  5.], dtype=float32)
```

要输出相加得到的结果，不能简单地直接输出 result，而需要先生成一个会话（session），并通过一个这个会话（session）来计算结果。到此，就实现了一个非常简单的 TensorFlow 模型。第3章将更加深入地介绍 TensorFlow 的基本概念，并将 TensorFlow 的计算模型和神经网络模型结合起来。

小结

在本章中首先介绍了 TensorFlow 主要依赖的两个工具——Protocol Buffer 和 Bazel。Protocol Buffer 是一个结构数据序列化的工具，在 TensorFlow 中大部分数据结构都是通过 Protocol Buffer 的形式存储的。Bazel 是一个谷歌开源的编译工具，在 2.2 节中讲解了如何通过 Bazel 编译 TensorFlow 的源代码。谷歌官方给出的大部分样例程序也是通过 Bazel 编译的。

在介绍完 TensorFlow 所依赖的工具之后，2.2 节讲解了 TensorFlow 的不同安装方式，以及不同安装方式适用的不同场景。2.2.1 小节中介绍的 Docker 是可移植性最强的一种安装方式，它支持大部分的操作系统（比如 Windows，Linux 和 Mac OS）。但 Docker 目前对

^① NumPy 是一个科学计算的 Python 工具包，<http://www.numpy.org> 中给出了更多关于 NumPy 的介绍。

GPU 的支持有限,而且 Docker 对本地开发环境的支持也不够友好。在本地最方便的安装方式是使用 pip。使用 pip 可以将已经打包好的安装包安装到本地。谷歌官方提供了不同版本 TensorFlow 的 pip 安装包。这种方式比较适合在本地开发 TensorFlow 的应用程序,但无法修改 TensorFlow 本身。最后一种方法就是从源码安装,这种方式最灵活,但比较烦琐。一般只有需要修改 TensorFlow 本身或者需要支持比较特殊的 GPU 时才会被用到。

在本章的最后一节中给出了一个非常简短的 TensorFlow 测试样例。这个样例程序完成了两个向量加法的功能。通过这个样例可以测试安装好的 TensorFlow 环境,同时也可以对 TensorFlow 有一个直观的感受。在第 3 章中将更加详细地介绍 TensorFlow 中的基本概念,并讲解如何通过 TensorFlow 来实现一个简单神经网络的训练过程。

第3章 TensorFlow 入门

在第2章中介绍了如何安装 TensorFlow，并且在安装好的 TensorFlow 中运行了一个简单的向量相加的样例。本章将详细地介绍 TensorFlow 基本概念。在本章的前3节中，将分别介绍 TensorFlow 的计算模型、数据模型和运行模型。通过这三个角度对 TensorFlow 的介绍，读者可以对 TensorFlow 的工作原理有一个大致的了解。在本章的最后一节中，将简单介绍神经网络的主要计算流程，并介绍如何通过 TensorFlow 实现这些计算。

3.1 TensorFlow 计算模型——计算图

计算图是 TensorFlow 中最基本的一个概念，TensorFlow 中的所有计算都会被转化为计算图上的节点。3.1.1 小节将详细介绍 TensorFlow 中计算图的基本概念，然后在 3.1.2 小节中将通过一些简单的样例程序说明 TensorFlow 计算图的使用方法。

3.1.1 计算图的概念

TensorFlow 的名字中已经说明了它最重要的两个概念——Tensor 和 Flow。Tensor 就是张量。张量这个概念在数学或者物理学中可以有不同的解释，但在本书中并不强调它本身的含义。在 TensorFlow 中，张量可以被简单地理解为多维数组，在 3.2 节中将对张量做更加详细的介绍。如果说 TensorFlow 的第一个词 Tensor 表明了它的数据结构，那么 Flow 则体现了它的计算模型。Flow 翻译成中文就是“流”，它直观地表达了张量之间通过计算相互转化的过程。TensorFlow 是一个通过计算图的形式来表述计算的编程系统。TensorFlow 中的每一个计算都是计算图上的一个节点，而节点之间的边描述了计算之间的依赖关系。图 3-1 展示了通过 TensorBoard^①画出来的第2章中两个向量相加样例的计算图。

^① TensorBoard 是 TensorFlow 的可视化工具，第9章将详细介绍这个工具。



图 3-1 通过 TensorBoard 可视化向量相加的计算图

图 3-1 中的每一个节点都是一个运算，而每一条边代表了计算之间的依赖关系。如果一个运算的输入依赖于另一个运算的输出，那么这两个运算有依赖关系。在图 3-1 中，a 和 b 这两个常量不依赖任何其他计算^①。而 add 计算则依赖读取两个常量的取值。于是在图 3-1 中可以看到有一条从 a 到 add 的边和一条从 b 到 add 的边。在图 3-1 中，没有任何计算依赖 add 的结果，于是代表加法的节点 add 没有任何指向其他节点的边。所有 TensorFlow 的程序都可以通过类似图 3-1 所示的计算图的形式来表示，这就是 TensorFlow 的基本计算模型。

3.1.2 计算图的使用

TensorFlow 程序一般可以分为两个阶段。在第一个阶段需要定义计算图中所有的计算。比如在第 2 章的向量加法样例程序中首先定义了两个输入，然后定义了一个计算来得到它们的和。第二个阶段为执行计算，这个阶段将在 3.3 节中介绍。以下代码给出了计算定义阶段的样例。

```
import tensorflow as tf
a = tf.constant([1.0, 2.0], name="a")
b = tf.constant([2.0, 3.0], name="b")
result = a + b
```

在 Python 中一般会采用“import tensorflow as tf”的形式来载入 TensorFlow，这样可以使使用“tf”来代替“tensorflow”作为模块名称，使得整个程序更加简洁。这是 TensorFlow 中非常常用的技巧，在本书后面的章节中将会全部采用这种加载方式。在这个过程中，TensorFlow 会自动将定义的计算转化为计算图上的节点。在 TensorFlow 程序中，系统会自动维护一个默认的计算图，通过 tf.get_default_graph 函数可以获取当前默认的计算图。以下代码示意了如何获取默认计算图以及如何查看一个运算所属的计算图。

```
# 通过 a.graph 可以查看张量所属的计算图。因为没有特意指定，所以这个计算图应该等于
# 当前默认的计算图。所以下面这个操作输出值为 True。
print(a.graph is tf.get_default_graph())
```

① 为了建模的方便，TensorFlow 会将常量转化成一种永远输出固定值的运算。

除了使用默认的计算图，TensorFlow 支持通过 `tf.Graph` 函数来生成新的计算图。不同计算图上的张量和运算都不会共享。以下代码示意了如何在不同计算图上定义和使用变量^①。

```
import tensorflow as tf

g1 = tf.Graph()
with g1.as_default():
    # 在计算图 g1 中定义变量“v”，并设置初始值为 0。
    v = tf.get_variable(
        "v", initializer=tf.zeros_initializer(shape=[1]))

g2 = tf.Graph()
with g2.as_default():
    # 在计算图 g2 中定义变量“v”，并设置初始值为 1。
    v = tf.get_variable(
        "v", initializer=tf.ones_initializer(shape=[1]))

# 在计算图 g1 中读取变量“v”的取值。
with tf.Session(graph=g1) as sess:
    tf.initialize_all_variables().run()
    with tf.variable_scope("", reuse=True):
        # 在计算图 g1 中，变量“v”的取值应该为 0，所以下面这行会输出[0.]。
        print(sess.run(tf.get_variable("v")))

# 在计算图 g2 中读取变量“v”的取值。
with tf.Session(graph=g2) as sess:
    tf.initialize_all_variables().run()
    with tf.variable_scope("", reuse=True):
        # 在计算图 g2 中，变量“v”的取值应该为 1，所以下面这行会输出[1.]。
        print(sess.run(tf.get_variable("v")))
```

上面的代码产生了两个计算图，每个计算图中定义了一个名字为“v”的变量。在计算图 g1 中，将 v 初始化为 0；在计算图 g2 中，将 v 初始化为 1。可以看到当运行不同计算图时，变量 v 的值也是不一样的。TensorFlow 中的计算图不仅仅可以用来隔离张量和计算，它还提供了管理张量和计算的机制。计算图可以通过 `tf.Graph.device` 函数来指定运行计算的设备。这为 TensorFlow 使用 GPU 提供了机制。下面的程序可以将加法计算跑在 GPU 上。

```
g = tf.Graph()
# 指定计算运行的设备。
with g.device('/gpu:0'):
    result = a + b
```

① 第 4 章将更加详细地介绍 TensorFlow 中变量的概念。

具体使用 GPU 的方法将在第 10 章详述。有效地整理 TensorFlow 程序中的资源也是计算图的一个重要功能。在一个计算图中，可以通过集合（collection）来管理不同类别的资源。比如通过 `tf.add_to_collection` 函数可以将资源加入一个或多个集合中，然后通过 `tf.get_collection` 获取一个集合里面的所有资源。这里的资源可以是张量、变量或者运行 TensorFlow 程序所需要的队列资源，等等。为了方便使用，TensorFlow 也自动管理了一些最常用的集合，表 3-1 总结了最常用的几个自动维护的集合。

表 3-1 TensorFlow 中维护的集合列表

集合名称	集合内容	使用场景
<code>tf.GraphKeys.VARIABLES</code>	所有变量	持久化 TensorFlow 模型
<code>tf.GraphKeys.TRAINABLE_VARIABLES</code>	可学习的变量（一般指神经网络中的参数）	模型训练、生成模型可视化内容
<code>tf.GraphKeys.SUMMARIES</code>	日志生成相关的张量	TensorFlow 计算可视化
<code>tf.GraphKeys.QUEUE_RUNNERS</code>	处理输入的 <code>QueueRunner</code>	输入处理
<code>tf.GraphKeys.MOVING_AVERAGE_VARIABLES</code>	所有计算了滑动平均值的变量	计算变量的滑动平均值

3.2 TensorFlow 数据模型——张量

3.1 节介绍了使用计算图的模型来描述 TensorFlow 中的计算。这一个节将介绍 TensorFlow 中另外一个基础概念——张量。张量是 TensorFlow 管理数据的形式，在 3.2.1 小节中将介绍张量的一些基本属性。然后在 3.2.2 小节中将介绍如何通过张量来保存和获取 TensorFlow 计算的结果。

3.2.1 张量的概念

从 TensorFlow 的名字就可以看出张量（tensor）是一个很重要的概念。在 TensorFlow 程序中，所有的数据都通过张量的形式来表示。从功能的角度上看，张量可以被简单理解为多维数组。其中零阶张量表示标量（scalar），也就是一个数^①；第一阶张量为向量（vector），也就是一个一维数组；第 n 阶张量可以理解为一个 n 维数组。但张量在 TensorFlow 中的实现并不是直接采用数组的形式，它只是对 TensorFlow 中运算结果的引用。在张量中并没有真正保存数字，它保存的是如何得到这些数字的计算过程。还是以向量加法为例，当运行

^① 张量的类型也可以是字符串，但在本书中不做过多的讨论。

如下代码时，并不会得到加法的结果，而会得到对结果的一个引用。

```
import tensorflow as tf
# tf.constant 是一个计算，这个计算的结果为一个张量，保存在变量 a 中。
a = tf.constant([1.0, 2.0], name="a")
b = tf.constant([2.0, 3.0], name="b")
result = tf.add(a, b, name="add")
print result
'''
输出：
Tensor("add:0", shape=(2,), dtype=float32)
'''
```

从上面的代码可以看出 TensorFlow 中的张量和 NumPy 中的数组不同，TensorFlow 计算的结果不是一个具体的数字，而且一个张量的结构。从上面代码的运行结果可以看出，一个张量中主要保存了三个属性：名字（name）、维度（shape）和类型（type）。

张量的第一个属性名字不仅是一个张量的唯一标识符，它同样也给出了这个张量是如何计算出来的。在 3.1.2 小节中介绍了 TensorFlow 的计算都可以通过计算图的模型来建立，而计算图上的每一个节点代表了一个计算，计算的结果就保存在张量之中。所以张量和计算图上节点所代表的计算结果是对应的。这样张量的命名就可以通过“node:src_output”的形式来给出。其中 node 为节点的名称，src_output 表示当前张量来自节点的第几个输出。比如上面代码打出来的“add:0”就说明了 result 这个张量是计算节点“add”输出的第一个结果（编号从 0 开始）。

张量的第二个属性是张量的维度（shape）。这个属性描述了一个张量的维度信息。比如上面样例中 shape=(2,) 说明了张量 result 是一个一维数组，这个数组的长度为 2。维度是张量一个很重要的属性，围绕张量的维度 TensorFlow 也给出了很多有用的运算，在这里先不一一列举，在后面的章节中将使用到部分运算。

张量的第三个属性是类型（type），每一个张量会有一个唯一的类型。TensorFlow 会对参与运算的所有张量进行类型的检查，当发现类型不匹配时会报错。比如运行下面这段程序时就会得到类型不匹配的错误：

```
import tensorflow as tf
a = tf.constant([1, 2], name="a")
b = tf.constant([2.0, 3.0], name="b")
result = a + b
```

这段程序和上面的样例基本一模一样，唯一不同的是把其中一个加数的小数点去掉了。这会使得加数 a 的类型为整数而加数 b 的类型为实数，这样程序会报类型不匹配的错误：

```
ValueError: Tensor conversion requested dtype int32 for Tensor with dtype float32: 'Tensor("b:0", shape=(2,), dtype=float32)'
```

如果将第一个加数指定成实数类型“`a = tf.constant([1, 2], name="a", dtype=tf.float32)`”，那么两个加数的类型相同就不会报错了。如果不指定类型，TensorFlow 会给出默认的类型，比如不带小数点的数会被默认为 `int32`，带小数点的会默认为 `float32`。因为使用默认类型有可能会产生潜在的类型不匹配问题，所以一般建议通过指定 `dtype` 来明确指出变量或者常量的类型。TensorFlow 支持 14 种不同的类型，主要包括了实数（`tf.float32`、`tf.float64`）、整数（`tf.int8`、`tf.int16`、`tf.int32`、`tf.int64`、`tf.uint8`）、布尔型（`tf.bool`）和复数（`tf.complex64`、`tf.complex128`）。

3.2.2 张量的使用

和 TensorFlow 的计算模型相比，TensorFlow 的数据模型相对比较简单。张量使用主要可以总结为两大类。

第一类用途是对中间计算结果的引用。当一个计算包含很多中间结果时，使用张量可以大大提高代码的可读性。以下为使用张量和不使用张量记录中间结果来完成向量相加的功能的代码对比。

```
# 使用张量记录中间结果
a = tf.constant([1.0, 2.0], name="a")
b = tf.constant([2.0, 3.0], name="b")
result = a + b

# 直接计算向量的和, 这样可读性会比较差。
result = tf.constant([1.0, 2.0], name="a") +
         tf.constant([2.0, 3.0], name="b")
```

从上面的样例程序可以看到 `a` 和 `b` 其实就是对常量生成这个运算结果的引用，这样在做加法时就可以直接使用这两个变量，而不需要再去生成这些常量。当计算的复杂度增加时（比如在构建深层神经网络时）通过张量来引用计算的中间结果可以使代码的可阅读性大大提升。同时通过张量来存储中间结果，这样可以方便获取中间结果。比如在卷积神经网络^①中，卷积层或者池化层有可能改变张量的维度，通过 `result.get_shape` 函数来获取结果张量的维度信息可以免去人工计算的麻烦。

使用张量的第二类情况是当计算图构造完成之后，张量可以用来获得计算结果，也就是得到真实的数字。虽然张量本身没有存储具体的数字，但是通过下面 3.3 小节中介绍的会话（`session`），就可以得到这些具体的数字。比如在上述代码中，可以使用 `tf.Session().run(result)` 语句来得到计算结果。

^① 第 6 章将介绍卷积神经网络。

3.3 TensorFlow 运行模型——会话

前面的两节介绍了 TensorFlow 是如何组织数据和运算的。本节将介绍如何使用 TensorFlow 中的会话（session）来执行定义好的运算。会话拥有并管理 TensorFlow 程序运行时的所有资源。当所有计算完成之后需要关闭会话来帮助系统回收资源，否则就可能出现资源泄漏的问题。TensorFlow 中使用会话的模式一般有两种，第一种模式需要明确调用会话生成函数和关闭会话函数，这种模式的代码流程如下。

```
# 创建一个会话。
sess = tf.Session()
# 使用这个创建好的会话来得到关心的运算的结果。比如可以调用 sess.run(result),
# 来得到 3.1 节样例中张量 result 的取值。
sess.run(...)
# 关闭会话使得本次运行中使用到的资源可以被释放。
sess.close()
```

使用这种模式时，在所有计算完成之后，需要明确调用 `Session.close` 函数来关闭会话并释放资源。然而，当程序因为异常而退出时，关闭会话的函数可能就不会被执行从而导致资源泄漏。为了解决异常退出时资源释放的问题，TensorFlow 可以通过 Python 的上下文管理器来使用会话。以下代码展示了如何使用这种模式。

```
# 创建一个会话，并通过 Python 中的上下文管理器来管理这个会话。
with tf.Session() as sess:
    # 使用这创建好的会话来计算关心的结果。
    sess.run(...)
# 不需要再调用“Session.close()”函数来关闭会话，
# 当上下文退出时会话关闭和资源释放也自动完成了。
```

通过 Python 上下文管理器的机制，只要将所有的计算放在“with”的内部就可以。当上下文管理器退出时候会自动释放所有资源。这样既解决了因为异常退出时资源释放的问题，同时也解决了忘记调用 `Session.close` 函数而产生的资源泄。

3.1 节介绍过 TensorFlow 会自动生成一个默认的计算图，如果没有特殊指定，运算会自动加入这个计算图中。TensorFlow 中的会话也有类似的机制，但 TensorFlow 不会自动生成默认的会话，而是需要手动指定。当默认的会话被指定之后可以通过 `tf.Tensor.eval` 函数来计算一个张量的取值。以下代码展示了通过设定默认会话计算张量的取值。

```
sess = tf.Session()
with sess.as_default():
    print(result.eval())
```

以下代码也可以完成相同的功能。


```
sess = tf.Session()

# 下面的两个命令有相同的功能。
print(sess.run(result))
print(result.eval(session=sess))
```

在交互式环境下（比如 Python 脚本或者 Jupyter 的编辑器下），通过设置默认会话的方式来获取张量的取值更加方便。所以 TensorFlow 提供了一种在交互式环境下直接构建默认会话的函数。这个函数就是 `tf.InteractiveSession`。使用这个函数会自动将生成的会话注册为默认会话。以下代码展示了 `tf.InteractiveSession` 函数的用法。

```
sess = tf.InteractiveSession ()
print(result.eval())
sess.close()
```

通过 `tf.InteractiveSession` 函数可以省去将产生的会话注册为默认会话的过程。无论使用哪种方法都可以通过 `ConfigProto Protocol Buffer`^①来配置需要生成的会话。下面给出了通过 `ConfigProto` 配置会话的方法：

```
config = tf.ConfigProto(allow_soft_placement=True,
                        log_device_placement=True)
sess1 = tf.InteractiveSession(config=config)
sess2 = tf.Session(config=config)
```

通过 `ConfigProto` 可以配置类似并行的线程数、GPU 分配策略、运算超时时间等参数。在这些参数中，最常使用的有两个。第一个是 `allow_soft_placement`，这是一个布尔型的参数，当它为 `True` 的时候，在以下任意一个条件成立的时候，GPU 上的运算可以放到 CPU 上进行：

1. 运算无法在 GPU 上执行。
2. 没有 GPU 资源（比如运算被指定在第二个 GPU 上运行，但是机器只有一个 GPU）。
3. 运算输入包含对 CPU 计算结果的引用。

这个参数的默认值为 `False`，但是为了使得代码的可移植性更强，在有 GPU 的环境下这个参数一般会被设置为 `True`。不同的 GPU 驱动版本可能对计算的支持有略微的区别，通过将 `allow_soft_placement` 参数设为 `True`，当某些运算无法被当前 GPU 支持时，可以自动调整到 CPU 上，而不是报错。类似的，通过将这个参数设置为 `True` 可以让程序在拥有不同数量的 GPU 机器上顺利运行。

第二个使用得比较多的配置参数是 `log_device_placement`。这也是一个布尔型的参数，当它为 `True` 时日志中将会记录每个节点被安排在了哪个设备上以方便调试。而在生产环境中将这个参数设置为 `False` 可以减少日志量。

① Protocol Buffer 在第 2 章中有介绍。

3.4 TensorFlow 实现神经网络

上面3节从不同角度介绍了TensorFlow的基本概念。在这一节中,将结合神经网络的功能进一步介绍如何通过TensorFlow来实现神经网络。首先3.4.1小节将通过TensorFlow游乐场来简单介绍神经网络的主要功能以及计算流程。然后3.4.2小节将介绍神经网络的前向传播算法(forward-propagation),并给出使用TensorFlow的代码实现。接着3.4.3小节将介绍如何通过TensorFlow中的变量来表达神经网络的参数。在3.4.4小节中将介绍神经网络反向传播(back-propagation)算法的原理以及TensorFlow对反向传播算法的支持。最后在3.4.5小节中将给出一个完整的TensorFlow程序在随机的数据上训练一个简单的神经网络。

3.4.1 TensorFlow 游乐场及神经网络简介

这一小节将通过TensorFlow游乐场来快速介绍神经网络的主要功能。TensorFlow游乐场(<http://playground.tensorflow.org>)是一个通过网页浏览器就可以训练的简单神经网络并实现了可视化训练过程的工具。图3-2给出了TensorFlow游乐场默认设置的截图。




图 3-2 TensorFlow 游乐场界面截图

从图3-2中可以看出,TensorFlow游乐场的左侧提供了4个不同的数据集来测试神经网络。默认的数据为左上角被框出来的那个。被选中的数据也会显示在图3-2中最右边的

“OUTPUT”栏下。在这个数据中，可以看到一个二维平面上有黑色或者灰色的点，每一个小点代表了一个样例，而点的颜色代表了样例的标签。因为点的颜色只有两种，所以这是一个二分类的问题。在这里举一个例子来说明这个数据可以代表的实际问题。假设需要判断某工厂生产的零件是否合格，那么灰色的点可以表示所有合格的零件而黑色的表示不合格的零件。这样判断一个零件是否合格就变成了区分点的颜色。

为了将一个实际问题对应到平面上不同颜色点的划分，还需要将实际问题中的实体，比如上述例子中的零件，变成平面上的一个点^①。这就是特征提取解决的问题。还是以零件为例，可以用零件的长度和质量来大致描述一个零件。这样一个物理意义上的零件就可以被转化成长度和质量这两个数字。在机器学习中，所有用于描述实体的数字的组合就是一个实体的特征向量（feature vector）。在第1章中介绍过，特征向量的提取对机器学习的效果至关重要，如何提取特征本书不再赘述。通过特征提取，就可以将实际问题中的实体转化为空间中的点。假设使用长度和质量作为一个零件的特征向量，那么每个零件就是二维平面上的一点。TensorFlow 游乐场中 FEATURES 一栏对应了特征向量。在本小节的样例中，可以认为 x_1 代表一个零件的长度，而 x_2 代表零件的质量。

特征向量是神经网络的输入，神经网络的主体结构显示在了图 3-2 的中间位置。目前主流的神经网络都是分层的结构，第一层是输入层，代表特征向量中每一个特征的取值。比如如果一个零件的长度是 0.5，那么 x_1 的值就是 0.5。同一层的节点不会相互连接，而且每一层只和下一层连接，直到最后一层作为输出层得到计算的结果^②。在二分类问题中，比如判断零件是否合格，神经网络的输出层往往只包含一个节点，而这个节点会输出一个实数值。通过这个输出值和一个事先设定的阈值，就可以得到最后的分类结果。以判断零件合格为例，可以认为当输出的数值大于 0 时，给出的判断结果是零件合格，反之则零件不合格。一般可以认为当输出值离阈值越远时得到的答案越可靠。

在输入和输出层之间的神经网络叫做隐藏层，一般一个神经网络的隐藏层越多，这个神经网络越“深”。而所谓深度学习中的这个“深度”和神经网络的层数也是密切相关的。在 TensorFlow 游乐场中可以通过点击“+”或者“-”来增加/减少神经网络隐藏层的数量。除了可以选择神经网络的深度，TensorFlow 游乐场也支持选择神经网络每一层的节点数以及学习率（learning rate）、激活函数（activation）、正则化（regularization）。如何使用这些参数将在后面的章节中讨论。在本小节中都直接使用 TensorFlow 游乐场默认的设置。当所有配置都选好之后，可以通过左上角的开始标志“●”来训练这个神经网络。图 3-3 中给出了迭代训练 100 轮之后的情况。

① 在真实问题中，一般会从实体中抽取更多的特征，所以一个实体会被表示为高维空间中的点。

② 有一些神经网络是可以跨层连接的，但目前大部分神经网络结构中都只是相邻两层有连接。

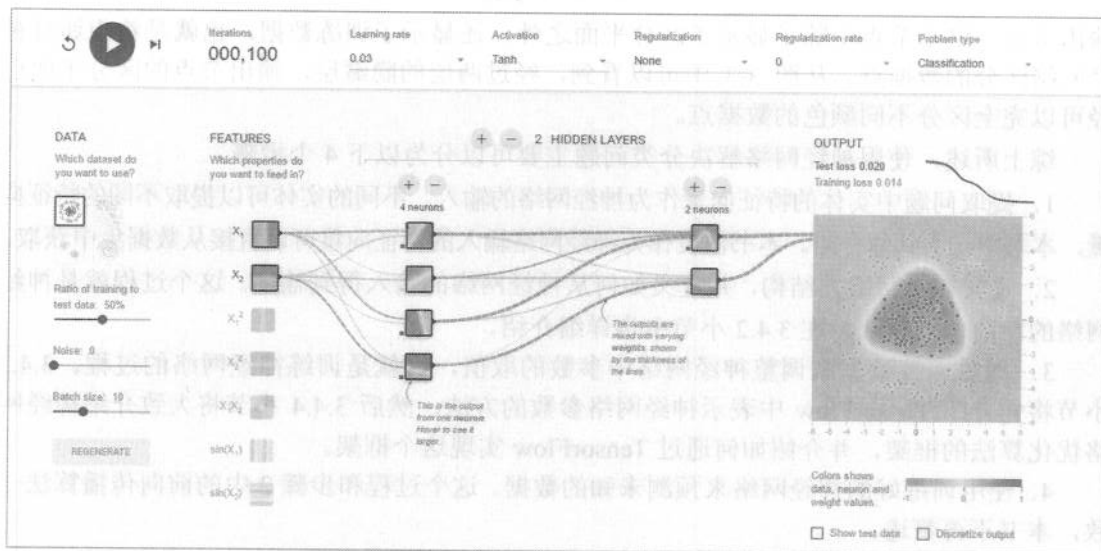


图 3-3 TensorFlow 游乐场训练 100 轮之后的截图

如何训练一个神经网络将在 3.4.4 小节中介绍，在这里主要介绍如何解读 TensorFlow 游乐场的训练结果。在图 3-3 中，一个小格子代表神经网络中的一个节点，而边代表节点之间的连接。每一个节点和边都被涂上了或深或浅的颜色，但边上的颜色和格子中的颜色含义有略微的区别。每一条边代表了神经网络中的一个参数，它可以是任意实数。神经网络就是通过对参数的合理设置来解决分类或者回归问题的。边上的颜色体现了这个参数的取值，当边的颜色越深时，这个参数取值的绝对值越大；当边的颜色接近白色时，这个参数的取值接近于 0^①。

每一个节点上的颜色代表了节点的区分平面。具体来说，如果把这个平面当成一个卡迪尔坐标系，这个平面上的每一个点就代表了 (x_1, x_2) 的一种取值。而这个点的颜色就体现了 x_1, x_2 在这种取值下这个节点的输出值。和边类似，当节点的输出值的绝对值越大时，颜色越深^②。下面将具体解读输入层 x_1 所代表的节点。从图 3-3 中可以看到 x_1 这个节点的区分平面就是 y 轴。因为这个节点的输出就是 x_1 本身的值，所以当 x_1 小于 0 时，这个节点的输出就是负数，而 x_1 大于 0 时输出的就是正数。于是 y 轴的左侧都为灰色，而右侧都为黑色^③。图 3-3 中其他节点可以类似的解读。唯一特殊的是最右边 OUTPUT 栏下的

① 在 TensorFlow 游乐场网站上，边的颜色有黄色（文中浅色部分）和蓝色（文中深色部分）的区别，黄色越深表示负得越大，蓝色越深表示正得越大。

② 类似边上的颜色，TensorFlow 游乐场网站中，点上的颜色也有黄色（文中浅色部分）和蓝色（文中深色部分），和边上颜色类似，黄色越深表示负得越大，蓝色越深表示正得越大。

③ 在 TensorFlow 游乐场中，y 轴左侧为黄色（文中浅色部分），右侧为蓝色（文中深色部分）。

输出节点。这个节点中除了显示了区分平面之外，还显示了训练数据，也就是希望通过神经网络区分的数据点。从图 3-3 中可以看到，经过两层的隐藏层，输出节点的区分平面已经可以完全区分不同颜色的数据点。

综上所述，使用神经网络解决分类问题主要可以分为以下 4 个步骤。

1. 提取问题中实体的特征向量作为神经网络的输入。不同的实体可以提取不同的特征向量，本书中将不具体介绍。本书假设作为神经网络输入的特征向量可以直接从数据集中获取。
2. 定义神经网络的结构，并定义如何从神经网络的输入得到输出。这个过程就是神经网络的前向传播算法，在 3.4.2 小节中将详细介绍。
3. 通过训练数据来调整神经网络中参数的取值，这就是训练神经网络的过程。3.4.3 小节将先介绍 TensorFlow 中表示神经网络参数的方法，然后 3.4.4 小节将大致介绍神经网络优化算法的框架，并介绍如何通过 TensorFlow 实现这个框架。
4. 使用训练好的神经网络来预测未知的数据。这个过程和步骤 2 中的前向传播算法一致，本书不再赘述。

下面的几个小节将具体介绍如何使用 TensorFlow 来实现神经网络中的不同步骤。最后在 3.4.5 小节将给出一个完成的程序来训练神经网络。

3.4.2 前向传播算法简介

在 3.4.1 小节中简单地介绍了神经网络可以将输入的特征向量经过层层推导得到最后的输出，并通过这些输出解决分类或者回归问题。那么神经网络的输出是如何得到的？在这一小节中将详细介绍解决这个问题的算法——前向传播算法。不同的神经网络结构前向传播的方式也不一样，本小节将介绍最简单的全连接网络结构的前向传播算法，并且将展示如何通过 TensorFlow 实现这个算法。为了介绍神经网络的前向传播算法，需要先了解神经元的结构。神经元是构成一个神经网络的最小单元，图 3-4 显示了一个最简单的神经元结构。




图 3-4 神经元结构示意图

从图 3-4 可以看出，一个神经元有多个输入和一个输出。每个神经元的输入既可以是其他神经元的输出，也可以是整个神经网络的输入。所谓神经网络的结构就是指的不同神经元之间的连接结构。如图 3-4 所示，一个最简单的神经元结构的输出就是所有输入的加权和^①，而不同输入的权重就是神经元的参数。神经网络的优化过程就是优化神经元中参数取值的过程，在后面的章节中将具体介绍。本小节将重点介绍神经网络的前向传播过程。图 3-5 给出了一个简单的判断零件是否合格的三层全连接神经网络。之所以称之为全连接神经网络是因为相邻两层之间任意两个节点之间都有连接。这也是为了将这样的网络结构和后面章节中将要介绍的卷积层、LSTM 结构区分。图 3-5 中除了输入层之外的所有节点都代表了一个神经元的结构。本小节将通过这个样例来解释前向传播的整个过程。




图 3-5 判断零件是否合格的三层神经网络结构图

计算神经网络的前向传播结果需要三部分信息。第一个部分是神经网络的输入，这个输入就是从实体中提取的特征向量。比如在图 3-5 中有两个输入，一个是零件的长度 x_1 ，一个是零件的质量 x_2 。第二个部分为神经网络的连接结构。神经网络是由神经元构成的，神经网络的结构给出不同神经元之间输入输出的连接关系。神经网络中的神经元也可以称之为节点，在本书之后的章节中将统一使用节点来指代神经网络中的神经元。在图 3-5 中， a_{11} 节点有两个输入，他们分别是 x_1 和 x_2 的输出。而 a_{11} 的输出则是节点 y 的输入。最后一

① 更加复杂的神经元结构将在第 4 章中介绍。

个部分是每个神经元中的参数。在图 3-5 中用 W 来表示神经元中的参数。 W 的上标表明了神经网络的层数, 比如 $W^{(1)}$ 表示第一层节点的参数, 而 $W^{(2)}$ 表示第二层节点的参数。 W 的下标表明了连接节点编号, 比如 $W_{1,2}^{(1)}$ 表示连接 x_1 和 a_{12} 节点的边上的权重。如何优化每一条边的权重将在下面的章节中介绍, 这一节假设这些权重是已知的。给定神经网络的输入, 神经网络的结构以及边上权重, 就可以通过前向传播算法来计算出神经网络的输出。图 3-6 展示了这个神经网络前向传播的过程。

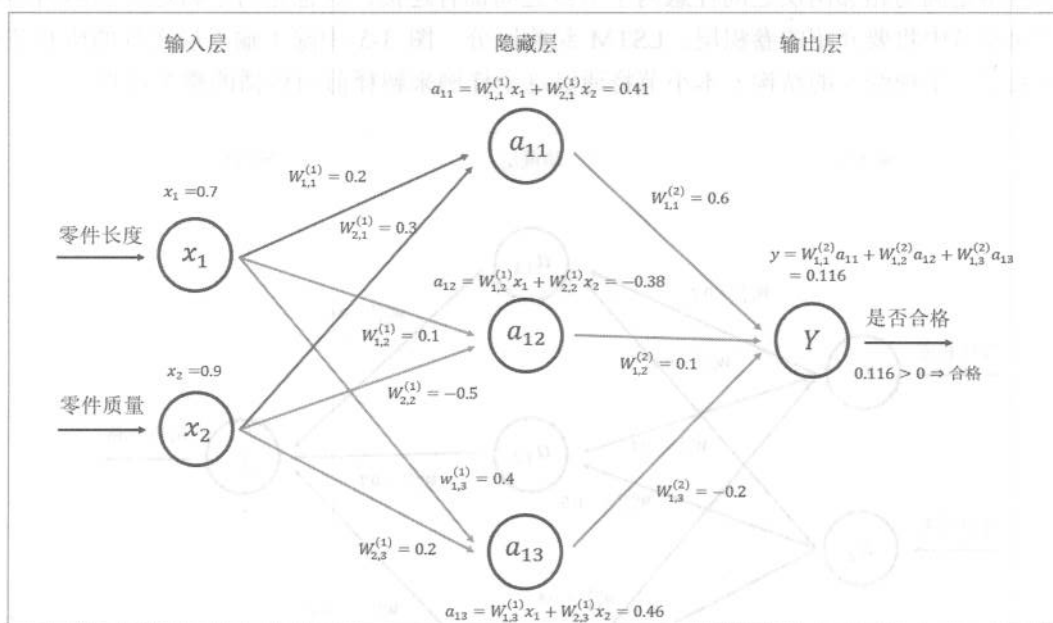


图 3-6 神经网络前向传播算法示意图

图 3-6 给出了输入层的取值 $x_1=0.7$ 和 $x_2=0.9$ 。从输入层开始一层一层地使用向前传播算法。首先隐藏层中有 3 个节点, 每一个节点的取值都是输入层取值的加权和。下面给出了 a_{11} 取值的详细计算过程:

$$a_{11} = W_{1,1}^{(1)}x_1 + W_{2,1}^{(1)}x_2 = 0.7 \times 0.2 + 0.9 \times 0.3 = 0.14 + 0.27 = 0.41$$

a_{12} 和 a_{13} 也可以通过类似的方法计算得到, 图 3-6 中也给出了具体的计算公式。在得到第一层节点的取值之后, 可以进一步推导得到输出层的取值。类似的, 输出层中节点的取值就是第一层的加权和:

$$\begin{aligned} y &= W_{1,1}^{(2)}a_{11} + W_{1,2}^{(2)}a_{12} + W_{1,3}^{(2)}a_{13} = 0.41 \times 0.6 + (-0.38) \times 0.1 + 0.46 \times (-0.2) \\ &= 0.246 + (-0.038) + (-0.092) = 0.116 \end{aligned}$$

因为这个输出值大于阈值 0, 所以在这个样例中最后给出的答案又是: 这个产品是合

格的。这就是整个前向传播的算法。前向传播算法可以表示为矩阵乘法。将输入 x_1, x_2 组织成一个 1×2 的矩阵 $x = [x_1, x_2]$ ，而 $W^{(1)}$ 组织成一个 2×3 的矩阵：

$$W^{(1)} = \begin{bmatrix} W_{1,1}^{(1)} & W_{1,2}^{(1)} & W_{1,3}^{(1)} \\ W_{2,1}^{(1)} & W_{2,2}^{(1)} & W_{2,3}^{(1)} \end{bmatrix}$$

这样通过矩阵乘法可以得到隐藏层三个节点所组成的向量取值：

$$\begin{aligned} a^{(1)} &= [a_{11}, a_{12}, a_{13}] = xW^{(1)} = [x_1, x_2] \begin{bmatrix} W_{1,1}^{(1)} & W_{1,2}^{(1)} & W_{1,3}^{(1)} \\ W_{2,1}^{(1)} & W_{2,2}^{(1)} & W_{2,3}^{(1)} \end{bmatrix} \\ &= [W_{1,1}^{(1)}x_1 + W_{2,1}^{(1)}x_2, W_{1,2}^{(1)}x_1 + W_{2,2}^{(1)}x_2, W_{1,3}^{(1)}x_1 + W_{2,3}^{(1)}x_2] \end{aligned}$$

类似的输出层可以表示为：

$$[y] = a^{(1)}W^{(2)} = [a_{11}, a_{12}, a_{13}] \begin{bmatrix} W_{1,1}^{(2)} \\ W_{2,1}^{(2)} \\ W_{3,1}^{(2)} \end{bmatrix} = [W_{1,1}^{(2)}a_{11} + W_{1,2}^{(2)}a_{12} + W_{1,3}^{(2)}a_{13}]$$

这样就将前向传播算法通过矩阵乘法的方式表达出来了。在 TensorFlow 中矩阵乘法是很容易实现的。以下 TensorFlow 程序实现了图 3-5 所示神经网络的前向传播过程。

```
a = tf.matmul(x, w1)
y = tf.matmul(a, w2)
```

其中 `tf.matmul` 实现了矩阵乘法的功能。到此为止已经详细地介绍了神经网络的前向传播算法，并且给出了 TensorFlow 程序来实现这个过程。在之后的章节中会继续介绍偏置 (bias)、激活函数 (activation function) 等更加复杂的神经元结构。也会介绍卷积神经网络，LSTM 结构等更加复杂的神经网络结构。对于这些更加复杂的神经网络，TensorFlow 也提供了很好的支持，后面的章节中再详细介绍。

3.4.3 神经网络参数与 TensorFlow 变量

神经网络中的参数是神经网络实现分类或者回归问题中重要的部分。本小节将更加具体地介绍 TensorFlow 是如何组织、保存以及使用神经网络中的参数的。在 TensorFlow 中，变量 (`tf.Variable`) 的作用就是保存和更新神经网络中的参数。和其他编程语言类似，TensorFlow 中的变量也需要指定初始值。因为在神经网络中，给参数赋予随机初始值最为常见，所以一般也使用随机数给 TensorFlow 中的变量初始化。下面一段代码给出了一种在 TensorFlow 中声明一个 2×3 的矩阵变量的方法：

```
weights = tf.Variable(tf.random_normal([2, 3], stddev=2))
```

这段代码调用了 TensorFlow 变量的声明函数 `tf.Variable`。在变量声明函数中给出了初始化这个变量的方法。TensorFlow 中变量的初始值可以设置成随机数、常数或者是通过其他变量的初始值计算得到。在上面的样例中，`tf.random_normal([2, 3], stddev=2)`会产生一个 2×3 的矩阵，矩阵中的元素是均值为 0，标准差为 2 的随机数。`tf.random_normal` 函数可以通过参数 `mean` 来指定平均值，在没有指定时默认为 0。通过满足正太分布的随机数来初始化神经网络中的参数是一个非常常用的方法。除了正太分布的随机数，TensorFlow 还提供了一些其他的随机数生成器，表 3-2 列出了 TensorFlow 目前支持的所有随机数生成器。

表 3-2 TensorFlow 随机数生成函数

函数名称	随机数分布	主要参数
<code>tf.random_normal</code>	正太分布	平均值、标准差、取值类型
<code>tf.truncated_normal</code>	正太分布，但如果随机出来的值偏离平均值超过 2 个标准差，那么这个数将会被重新随机	平均值、标准差、取值类型
<code>tf.random_uniform</code>	平均分布	最小、最大取值，取值类型
<code>tf.random_gamma</code>	Gamma 分布	形状参数 <code>alpha</code> 、尺度参数 <code>beta</code> 、取值类型

TensorFlow 也支持通过常数来初始化一个变量。表 3-3 给出了 TensorFlow 中常用的常量声明方法。

表 3-3 TensorFlow 常数生成函数

函数名称	功能	样例
<code>tf.zeros</code>	产生全 0 的数组	<code>tf.zeros([2, 3], int32) -> [[0, 0, 0], [0, 0, 0]]</code>
<code>tf.ones</code>	产生全 1 的数组	<code>tf.ones([2, 3], int32) -> [[1, 1, 1], [1, 1, 1]]</code>
<code>tf.fill</code>	产生一个全部为给定数字的数组	<code>tf.fill([2, 3], 9) -> [[9, 9, 9], [9, 9, 9]]</code>
<code>tf.constant</code>	产生一个给定值的常量	<code>tf.constant([1, 2, 3]) -> [1, 2, 3]</code>

在神经网络中，偏置项 (bias) 通常会使用常数来设置初始值。以下代码给出了一个样例。

```
biases = tf.Variable(tf.zeros([3]))
```

这段代码将会生成一个初始值全部为 0 且长度为 3 的变量。除了使用随机数或者常数，TensorFlow 也支持通过其他变量的初始值来初始化新的变量。以下代码给出了具体的方法。

```
w2 = tf.Variable(weights.initialized_value())  
w3 = tf.Variable(weights.initialized_value() * 2.0)
```

以上代码中，`w2` 的初始值被设置成了与 `weights` 变量相同。`w3` 的初始值则是 `weights` 初始值的两倍。在 TensorFlow 中，一个变量的值在被使用之前，这个变量的初始化过程需要被明确地调用。以下样例介绍了如何通过变量实现神经网络的参数并实现前向传播的过程。

```

import tensorflow as tf

# 声明 w1、w2 两个变量。这里还通过 seed 参数设定了随机种子，
# 这样可以保证每次运行得到的结果是一样的。
w1 = tf.Variable(tf.random_normal([2, 3], stddev=1, seed=1))
w2 = tf.Variable(tf.random_normal([3, 1], stddev=1, seed=1))

# 暂时将输入的特征向量定义为一个常量。注意这里 x 是一个 1*2 的矩阵。
x = tf.constant([[0.7, 0.9]])

# 通过 3.4.2 小节描述的前向传播算法获得神经网络的输出。
a = tf.matmul(x, w1)
y = tf.matmul(a, w2)

sess = tf.Session()
# 与 3.4.2 中的计算不同，这里不能直接通过 sess.run(y) 来获取 y 的取值，
# 因为 w1 和 w2 都还没有运行初始化过程。下面的两行分别初始化了 w1 和 w2 两个变量。
sess.run(w1.initializer) # 初始化 w1
sess.run(w2.initializer) # 初始化 w2
# 输出 [[3.95757794]]
print(sess.run(y))
sess.close()

```

上面这段程序实现了神经网络的前向传播过程。从这段代码可以看到，当声明了变量 `w1`、`w2` 之后，可以通过 `w1` 和 `w2` 来定义神经网络的前向传播过程并得到中间结果 `a` 和最后答案 `y`。定义 `w1`、`w2`、`a` 和 `y` 的过程对应了 3.1.2 小节中介绍的 TensorFlow 程序的第一步。这一步定义了 TensorFlow 计算图中所有的计算，但这些被定义的计算在这一步中并不真正的运行。当需要运行这些计算并得到具体数字时，需要进入 TensorFlow 程序的第二步。

在 TensorFlow 程序的第二步会声明一个会话 (session)，并通过会话计算结果。在上面的样例中，当会话定义完成之后就可以开始真正运行定义好的计算了。但在计算 `y` 之前，需要将所有用到的变量初始化。也就是说，虽然在变量定义时给出了变量初始化的方法，但这个方法并没有被真正运行。所以在计算 `y` 之前，需要通过运行 `w1.initializer` 和 `w2.initializer` 来给变量赋值。虽然直接调用每个变量的初始化过程是一个可行的方案，但是当变量数目增多，或者变量之间存在依赖关系时，单个调用的方案就比较麻烦了。为了解决这个问题，TensorFlow 提供了一种更加便捷的方式来完成变量初始化过程。下面的程序展示了通过 `tf.initialize_all_variables` 函数实现初始化所有变量的过程。

```

init_op = tf.initialize_all_variables()
sess.run(init_op)

```

通过 `tf.initialize_all_variables` 函数，就不需要将变量一个一个初始化了。这个函数也会自动处理变量之间的依赖关系。下面的章节都将使用这个函数来完成变量的初始化过程。

在 3.2 节中介绍过 TensorFlow 的核心概念是张量 (tensor)，所有的数据都是通过张量的形式来组织的，那么本小节介绍的变量和张量是什么关系呢？在 TensorFlow 中，变量的声明函数 `tf.Variable` 是一个运算。这个运算的输出结果就是一个张量，这个张量也就是本节中介绍的变量。所以变量只是一种特殊的张量。下面将进一步介绍 `tf.Variable` 操作在 TensorFlow 中底层是如何实现的。图 3-7 给出了神经网络前向传播样例程序的 TensorFlow 计算图的一个部分，这个部分显示了和变量 `w1` 相关的操作。




图 3-7 神经网络前向传播样例中变量 `w1` 相关部分的计算图可视化结果^①

在图 3-7 上黑色的椭圆代表了变量 `w1`，可以看到 `w1` 是一个 `Variable` 运算。在这张图的下方可以看到 `w1` 通过一个 `read` 操作将值提供给了一个乘法运算，这个乘法操作就是 `tf.matmul(x, w1)`。初始化变量 `w1` 的操作是通过 `Assign` 操作完成的。在图 3-7 上可以看到 `Assign` 这个节点的输入为随机数生成函数的输出，而且输出赋给了变量 `w1`。这样就完成了变量初始化的过程。

3.1.2 小节介绍了 TensorFlow 中集合 (collection) 的概念，所有的变量都会被自动的加入 `GraphKeys.VARIABLES` 这个集合。通过 `tf.all_variables` 函数可以拿到当前计算图上所有的变量。拿到计算图上所有的变量有助于持久化整个计算图的运行状态，在第 5 章中将更加详细地介绍。当构建机器学习模型时，比如神经网络，可以通过变量声明函数中的 `trainable` 参数来区分需要优化的参数 (比如神经网络中的参数) 和其他参数 (比如迭代的轮数)。如果声明变量时参数 `trainable` 为 `True`，那么这个变量将会被加入 `GraphKeys.TRAINABLE_VARIABLES` 集合。在 TensorFlow 中可以通过 `tf.trainable_variables` 函数得到所有需要优化

^① 此图是通过 TensorBoard 可视化工具绘制的，将在第 9 章中详细介绍 TensorBoard。

的参数。TensorFlow 中提供的神经网络优化算法会将 `GraphKeys.TRAINABLE_VARIABLES` 集合中的变量作为默认的优化对象。

类似张量，维度（`shape`）和类型（`type`）也是变量最重要的两个属性。和大部分程序语言类似，变量的类型是不可改变的。一个变量在构建之后，它的类型就不能再改变了。比如在上面给出的前向传播样例中，`w1` 的类型为 `random_normal` 结果的默认类型 `tf.float32`，那么它将被赋予其他类型的值。以下代码将会报出类型不匹配的错误。

```
w1 = tf.Variable(tf.random_normal([2, 3], stddev=1), name="w1")
w2 = tf.Variable(tf.random_normal([2, 3], dtype=tf.float64, stddev=1),
                 name="w2")
w1.assign(w2)
```

'''

程序将报错：

```
TypeError: Input 'value' of 'Assign' Op has type float64 that does not match
type float32 of argument 'ref'.
```

'''

维度是变量另一个重要的属性。和类型不大一样的是，维度在程序运行中是有可能改变的，但是需要通过设置参数 `validate_shape=False`。下面给出了一段示范代码。

```
w1 = tf.Variable(tf.random_normal([2, 3], stddev=1), name="w1")
w2 = tf.Variable(tf.random_normal([2, 2], stddev=1), name="w2")
# 下面这句会报维度不匹配的错误：
# ValueError: Shapes (2, 3) and (2, 2) are not compatible
tf.assign(w1, w2)
# 这一句可以被成功执行。
tf.assign(w1, w2, validate_shape=False)
```

虽然 TensorFlow 支持更改变量的维度，但是这种用法在实践中比较罕见。

3.4.4 通过 TensorFlow 训练神经网络模型

3.4.3 小节介绍了如何通过 TensorFlow 变量来表示神经网络中的参数，并给出了一个样例程序来完成神经网络的前向传播过程。在这个样例程序中，所有变量的取值都是随机的。在使用神经网络解决实际分类或者回归问题时（比如判断一个零件是否合格）需要更好地设置参数取值。这一小节将简单介绍使用监督学习的方式来更合理地设置参数取值，同时也将给出 TensorFlow 程序来完成这个过程。设置神经网络参数的过程就是神经网络的训练过程。只有经过有效训练的神经网络模型才可以真正地解决分类或者回归问题。图 3-8

对比了训练之前和训练之后神经网络模型的分类效果。从图中可以看出，模型在训练之前是完全无法区分黑色点和灰色点的，但经过训练之后区分效果已经很好了。




图 3-8 TensorFlow 游乐场训练前和训练后效果对比

使用监督学习的方式设置神经网络参数需要有一个标注好的训练数据集。以判断零件是否合格为例，这个标注好的训练数据集就是收集的一批合格零件和一批不合格零件。在图 3-8 中，图上黑色点和灰色点代表的就是训练数据集，而平面上或深或浅的颜色表示了神经网络模型做出的判断。如 3.4.1 小节所介绍的，一个地方的颜色越深，那么表示神经网络模型对它的判断越有信心^①。左侧的图片显示的是一个神经网络在训练之前的分类效果，这时所有变量的取值都是随机数。可以看到这个平面上的颜色都很浅，而且完全区分不出灰色点和黑色点。右侧图片显示了经过训练后的神经网络的情况。可以看到图上黑色点和灰色点可以很清晰地被区分开来，而且除了中间有一圈是浅色的，其他地方神经网络都可以给出非常确定的答案。

监督学习最重要的思想就是，在已知答案的标注数据集上，模型给出的预测结果要尽量接近真实的答案。通过调整神经网络中的参数对训练数据进行拟合，可以使得模型对未知的样本提供预测的能力。图 3-8 中右侧图片中右上角的深色点就很有可能和灰色点有相同的标签。如果灰色点代表不合格的零件，那么这个深色点所代表的零件应该也不合格。

在神经网络优化算法中，最常用的方法是反向传播算法（backpropagation）。反向传播算法的具体工作原理将在下面的 4.3 小节中详述。本小节将主要介绍训练神经网络的整体流程以及 TensorFlow 对于这个流程的支持。图 3-9 展示了使用反向传播算法训练神经网络的流程图。

^① 在 TensorFlow 游乐场有两种颜色，一种黄色（文中浅色部分），一种蓝色（文中深色部分）。任意一种颜色越深，都代表判断的信心越大。

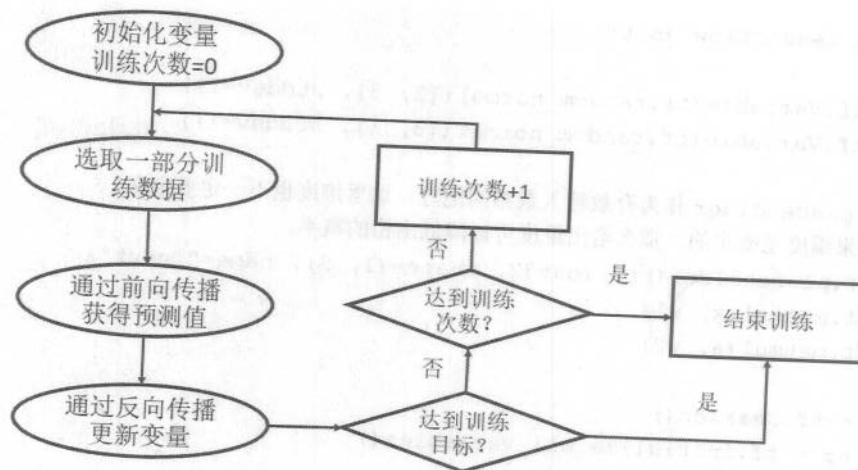


图 3-9 神经网络反向传播优化流程图

从图 3-9 中可以看出，反向传播算法实现了一个迭代的过程。在每次迭代的开始，首先需要选取一小部分训练数据，这一小部分数据叫做一个 batch。然后，这个 batch 的样例会通过前向传播算法得到神经网络模型的预测结果。因为训练数据都是有正确答案标注的，所以可以计算出当前神经网络模型的预测答案与正确答案之间的差距。最后，基于这预测值和真实值之间的差距，反向传播算法会相应更新神经网络参数的取值，使得在这个 batch 上神经网络模型的预测结果和真实答案更加接近。

通过 TensorFlow 实现反向传播算法的第一步是使用 TensorFlow 表达一个 batch 的数据。在 3.4.3 小节中尝试过使用常量来表达过一个样例：

```
x = tf.constant([[0.7, 0.9]])
```

但如果每轮迭代中选取的数据都要通过常量来表示，那么 TensorFlow 的计算图将会太大。因为每生成一个常量，TensorFlow 都会在计算图中增加一个节点。一般来说，一个神经网络的训练过程会需要经过几百万轮甚至几亿轮的迭代，这样计算图就会非常大，而且利用率很低。为了避免这个问题，TensorFlow 提供了 placeholder 机制用于提供输入数据。placeholder 相当于定义了一个位置，这个位置中的数据在程序运行时再指定。这样在程序中就不需要生成大量常量来提供输入数据，而只需要将数据通过 placeholder 传入 TensorFlow 计算图。在 placeholder 定义时，这个位置上的数据类型是需要指定的。和其他张量一样，placeholder 的类型也是不可以改变的。placeholder 中数据的维度信息可以根据提供的数据推导得出，所以不一定要给出。下面给出了通过 placeholder 实现前向传播算法的代码。

```
import tensorflow as tf

w1 = tf.Variable(tf.random_normal([2, 3], stddev=1))
w2 = tf.Variable(tf.random_normal([3, 1], stddev=1))

# 定义placeholder 作为存放输入数据的地方。这里维度也不一定要定义。
# 但如果维度是确定的，那么给出维度可以降低出错的概率。
x = tf.placeholder(tf.float32, shape=(1, 2), name="input")
a = tf.matmul(x, w1)
y = tf.matmul(a, w2)

sess = tf.Session()
init_op = tf.initialize_all_variables()
sess.run(init_op)

# 下面一行将报错: InvalidArgumentError: You must feed a value for placeholder
# tensor 'input_1' with dtype float and shape [1,2]
print(sess.run(y))

# 下面一行将会得到和 3.4.2 小节中一样的输出结果: [[3.95757794]]
print(sess.run(y, feed_dict={x: [[0.7, 0.9]]}))
```

在这段程序中替换了原来通过常量定义的输入 x 。在新的程序中计算前向传播结果时，需要提供一个 `feed_dict` 来指定 x 的取值。`feed_dict` 是一个字典 (map)，在字典中需要给出每个用到的 `placeholder` 的取值。如果某个需要的 `placeholder` 没有被指定取值，那么程序在运行时将会报错。

上面的程序只计算了一个样例的前向传播结果，但如图 3-9 所示，在训练神经网络时需要每次提供一个 batch 的训练样例。对于这样的需求，`placeholder` 也可以很好地支持。在上面的样例程序中，如果将输入的 1×2 矩阵改为 $n \times 2$ 的矩阵，那么就可以得到 n 个样例的前向传播结果了。其中 $n \times 2$ 的矩阵的每一行为一个样例数据。这样前向传播的结果为 $n \times 1$ 的矩阵，这个矩阵的每一行就代表了一个样例的前向传播结果。下面的程序片给出了一个示例。

```
x = tf.placeholder(tf.float32, shape=(3, 2), name="input")
... # 中间部分和上面的样例程序一样。

# 因为 x 在定义时指定了 n 为 3，所以在运行前向传播过程时需要提供 3 个样例数据。
print(sess.run(y, feed_dict={x: [[0.7, 0.9], [0.1, 0.4], [0.5, 0.8]]}))
```

```
'''
输出结果为:
[[ 3.95757794]
 [ 1.15376544]
 [ 3.16749191]]
'''
```

上面的样例展示了一次性计算多个样例的前向传播结果。在运行时,需要将 3 个样例 [0.7,0.9]、[0.1,0.4]和[0.5,0.8]组成一个 3×2 的矩阵传入 `placeholder`。计算得到的结果为 3×1 的矩阵。其中第一行 3.95757794 为样例[0.7,0.9]的前向传播结果;1.15376544 为样例[0.1,0.4]的前向传播结果;3.16749191 为样例[0.5,0.8]的前向传播结果。

在得到一个 `batch` 的前向传播结果之后,需要定义一个损失函数来刻画当前的预测值和真实答案之间的差距。然后通过反向传播算法来调整神经网络参数的取值使得差距可以被缩小。损失函数和反向传播算法将在第 4 章中更加详细地介绍。以下代码定义了一个简单的损失函数,并通过 TensorFlow 定义了反向传播的算法。

```
# 定义损失函数来刻画预测值与真实值得差距。
cross_entropy = -tf.reduce_mean(
    y_ * tf.log(tf.clip_by_value(y, 1e-10, 1.0)))
# 定义学习率,在第 4 章中将更加具体的介绍学习率。
learning_rate = 0.001
# 定义反向传播算法来优化神经网络中的参数。
train_step = \
    tf.train.AdamOptimizer(learning_rate).minimize(cross_entropy)
```

在上面的代码中, `cross_entropy` 定义了真实值和预测值之间的交叉熵^①(cross entropy),这是分类问题中一个常用的损失函数。第二行 `train_step` 定义了反向传播的优化方法。目前 TensorFlow 支持 7 种不同的优化器,读者可以根据具体的应用选择不同的优化算法。比较常用的优化方法有三种: `tf.train.GradientDescentOptimizer`、`tf.train.AdamOptimizer` 和 `tf.train.MomentumOptimizer`。在定义了反向传播算法之后,通过运行 `sess.run(train_step)`就可以对所有在 `GraphKeys.TRAINABLE_VARIABLES` 集合中的变量^②进行优化,使得在当前 batch 下损失函数更小。下面的 3.4.5 小节将给出一个完整的训练神经网络样例程序。

3.4.5 完整神经网络样例程序

本小节将在一个模拟数据集上训练神经网络。下面给出了一个完整的程序来训练神经

① 在第 4 章中将更加具体的介绍交叉熵损失函数。

② TensorFlow 计算图中集合的概念在 3.1.2 小节有介绍。

网络解决二分类问题。

```
import tensorflow as tf

# NumPy 是一个科学计算的工具包，这里通过 NumPy 工具包生成模拟数据集。
from numpy.random import RandomState

# 定义训练数据 batch 的大小。
batch_size = 8

# 定义神经网络的参数，这里还是沿用 3.4.2 小节中给出的神经网络结构。
w1 = tf.Variable(tf.random_normal([2, 3], stddev=1, seed=1))
w2 = tf.Variable(tf.random_normal([3, 1], stddev=1, seed=1))

# 在 shape 的一个维度上使用 None 可以方便使用不大的 batch 大小。在训练时需要把数据分
# 成比较小的 batch，但是在测试时，可以一次性使用全部的数据。当数据集比较小时这样比较
# 方便测试，但数据集比较大时，将大量数据放入一个 batch 可能会导致内存溢出。
x = tf.placeholder(tf.float32, shape=(None, 2), name='x-input')
y_ = tf.placeholder(tf.float32, shape=(None, 1), name='y-input')

# 定义神经网络前向传播的过程。
a = tf.matmul(x, w1)
y = tf.matmul(a, w2)

# 定义损失函数和反向传播的算法。
cross_entropy = -tf.reduce_mean(
    y_ * tf.log(tf.clip_by_value(y, 1e-10, 1.0)))
train_step = tf.train.AdamOptimizer(0.001).minimize(cross_entropy)

# 通过随机数生成一个模拟数据集。
rdm = RandomState(1)
dataset_size = 128
X = rdm.rand(dataset_size, 2)

# 定义规则来给出样本的标签。在这里所有  $x_1+x_2 < 1$  的样例都被认为是正样本（比如零件合格），
# 而其他为负样本（比如零件不合格）。和 TensorFlow 游乐场中的表示法不大一样的地方是，
# 在这里使用 0 来表示负样本，1 来表示正样本。大部分解决分类问题的神经网络都会采用
# 0 和 1 的表示方法。
Y = [[int( $x_1+x_2 < 1$ )] for ( $x_1, x_2$ ) in X]

# 创建一个会话来运行 TensorFlow 程序。
with tf.Session() as sess:
    init_op = tf.initialize_all_variables()
    # 初始化变量。
    sess.run(init_op)
```



```
print sess.run(w1)
print sess.run(w2)
'''
```

在训练之前神经网络参数的值:

```
w1 = [[-0.81131822, 1.48459876, 0.06532937]
      [-2.44270396, 0.0992484, 0.59122431]]
w2 = [[-0.81131822], [1.48459876], [0.06532937]]
'''
```

设定训练的轮数。

```
STEPS = 5000
```

```
for i in range(STEPS):
```

每次选取 batch_size 个样本进行训练。

```
start = (i * batch_size) % dataset_size
```

```
end = min(start+batch_size, dataset_size)
```

通过选取的样本训练神经网络并更新参数。

```
sess.run(train_step,
```

```
      feed_dict={x: X[start:end], y_: Y[start:end]})
```

```
if i % 1000 == 0:
```

每隔一段时间计算在所有数据上的交叉熵并输出。

```
total_cross_entropy = sess.run(
```

```
    cross_entropy, feed_dict={x: X, y_: Y})
```

```
print("After %d training step(s), cross entropy on all data is %g" %
      (i, total_cross_entropy))
```

```
'''
```

输出结果:

```
After 0 training step(s), cross entropy on all data is 0.0674925
After 1000 training step(s), cross entropy on all data is 0.0163385
After 2000 training step(s), cross entropy on all data is 0.00907547
After 3000 training step(s), cross entropy on all data is 0.00714436
After 4000 training step(s), cross entropy on all data is 0.00578471
```

通过这个结果可以发现随着训练的进行, 交叉熵是逐渐变小的。交叉熵越小说明预测的结果和真实的结果差距越小。

```
'''
```

```
print sess.run(w1)
```

```
print sess.run(w2)
```

```
'''
```

在训练之后神经网络参数的值:

```
w1 = [[-1.9618274, 2.58235407, 1.68203783]
      [-3.4681716, 1.06982327, 2.11788988]]
w2 = [[-1.8247149], [2.68546653], [1.41819501]]
```


可以发现这两个参数的取值已经发生了变化，这个变化就是训练的结果。它使得这个神经网络能更好的拟合提供的训练数据。

上面的程序实现了训练神经网络的全部过程。从这段程序可以总结出训练神经网络的过程可以分为以下 3 个步骤：

1. 定义神经网络的结构和前向传播的输出结果。
 2. 定义损失函数以及选择反向传播优化的算法。
 3. 生成会话 (tf.Session) 并且在训练数据上反复运行反向传播优化算法。
- 无论神经网络的结构如何变化，这 3 个步骤是不变的。

小结

本章首先介绍了 TensorFlow 里最基本的三个概念——计算图 (tf.Graph)、张量 (tf.Tensor) 和会话 (tf.Session)。在 3.1 节中，介绍了 TensorFlow 中计算图的概念。计算图是 TensorFlow 的计算模型，所有 TensorFlow 的程序都会通过计算图的形式表示。计算图上的每一个节点都是一个运算，而计算图上的边则表示了运算之间的数据传递关系。计算图上还保存了运行每个运算的设备信息（比如是通过 CPU 上还是 GPU 运行）以及运算之间的依赖关系。计算图提供了管理不同集合的功能，并且 TensorFlow 会自动维护五个不同的默认集合。3.2 节介绍了张量的概念。张量是 TensorFlow 的数据模型，TensorFlow 中所有运算的输入、输出都是张量。张量本身并不存储任何数据，它只是对运算结果的引用。通过张量，可以更好地组织 TensorFlow 程序。接着 3.3 节介绍了 TensorFlow 中的会话。会话是 TensorFlow 的运算模型，它管理了一个 TensorFlow 程序拥有的系统资源，所有的运算都要通过会话执行。

本章的最后一节介绍了如何使用 TensorFlow 来实现神经网络的训练过程。首先 3.4.1 小节结合 TensorFlow 游乐场简单介绍了神经网络的大致功能，并介绍了使用神经网络的几个主要步骤。然后在接下来的 3.4.2 到 3.4.4 小节中，依次介绍了神经网络的前向传播算法、神经网络中的参数在 TensorFlow 中的表示以及神经网络的反向传播优化算法框架。综合这 3 个小节的内容，最后 3.4.5 小节给出了一个完整的 TensorFlow 程序来训练神经网络。在下面的第 4 章中，将更加深入地介绍设计和优化神经网络中的细节。

第 4 章 深层神经网络

第 3 章介绍了 TensorFlow 的主要概念，并且给出了一个完整的 TensorFlow 程序来训练神经网络。在这一章中，将进一步介绍如何设计和优化神经网络，使得它能够更好地对未知的样本进行预测。首先在 4.1 节中，将介绍深度学习与深层神经网络的概念，并给出一个实际的样例来说明深层神经网络可以解决部分浅层神经网络解决不了的问题。然后在 4.2 节中，将介绍如何设定神经网络的优化目标。这个优化目标也就是损失函数。这一节将分别介绍分类问题和回归问题中比较常用的几种损失函数。除了使用经典的损失函数外，在这一节中将给出一个样例来讲解如何通过对损失函数的设置，使神经网络优化的目标更加接近实际需求。接着，4.3 节将更加详细地介绍神经网络的反向传播算法，并且给出一个 TensorFlow 框架来实现反向传播的过程。在对神经网络优化有了进一步了解之后，最后 4.4 节将介绍在神经网络优化中经常遇到的几个问题，并且给出解决这些问题的具体方法。

4.1 深度学习与深层神经网络

维基百科对深度学习的精确定义为“一类通过多层非线性变换对高复杂性数据建模算法的合集”^①。因为深层神经网络是实现“多层非线性变换”最常用的一种方法，所以在实际中基本上可以认为深度学习就是深层神经网络的代名词。从维基百科给出的定义可以看出，深度学习有两个非常重要的特性——多层和非线性。那么为什么要强调这两个性质？本小节将给出详细的解释，并且将通过具体的样例来说明这两点在对复杂问题建模时是缺一不可的。4.1.1 小节将先介绍线性变换存在的问题，以及为什么要在深度学习的定义中强调“复杂问题”。然后在 4.1.2 小节中，将介绍如何实现去线性化，并给出 TensorFlow 程序来实现去线性化的功能。最后 4.1.3 小节将介绍一个具体的样例来说明深层网络比浅层网络

^① 具体定义可以参考维基百科：https://en.wikipedia.org/wiki/Deep_learning。

可以解决更多的问题。

4.1.1 线性模型的局限性

在线性模型中，模型的输出为输入的加权和。假设一个模型的输出 y 和输入 x_i 满足以下关系，那么这个模型就是一个线性模型。

$$y = \sum_i w_i x_i + b$$

其中 $w_i, b \in R$ 为模型的参数。被称之为线性模型是因为当模型的输入只有一个的时候， x 和 y 形成了二维坐标系上的一条直线。类似的，当模型有 n 个输入时， x 和 y 形成了 $n+1$ 维空间中的一个平面。而一个线性模型中通过输入得到输出的函数被称之为一个线性变换。上面的公式就是一个线性变换。线性模型的最大特点是任意线性模型的组合仍然还是线性模型。细心的读者可能已经注意到了，3.4.2 小节中所介绍的前向传播算法实现的就是一个线性模型。在 3.4.2 小节中，前向传播的计算公式为：

$$a^{(1)} = xW^{(1)}, y = a^{(1)}W^{(2)}$$

其中 x 为输入， W 为参数。整理一下上面的公式可以得到整个模型的输出为：

$$y = (xW^{(1)})W^{(2)}$$

根据矩阵乘法的结合律有：

$$y = x(W^{(1)}W^{(2)}) = xW'$$

而 $W^{(1)}W^{(2)}$ 其实可以被表示为一个新的参数 W' ：

$$W' = W^{(1)}W^{(2)} = \begin{bmatrix} W_{1,1}^{(1)} & W_{1,2}^{(1)} & W_{1,3}^{(1)} \\ W_{2,1}^{(1)} & W_{2,2}^{(1)} & W_{2,3}^{(1)} \end{bmatrix} \begin{bmatrix} W_{1,1}^{(2)} \\ W_{2,1}^{(2)} \\ W_{3,1}^{(2)} \end{bmatrix} = \begin{bmatrix} W_{1,1}^{(1)}W_{1,1}^{(2)} + W_{1,2}^{(1)}W_{2,1}^{(2)} + W_{1,3}^{(1)}W_{3,1}^{(2)} \\ W_{2,1}^{(1)}W_{1,1}^{(2)} + W_{2,2}^{(1)}W_{2,1}^{(2)} + W_{2,3}^{(1)}W_{3,1}^{(2)} \end{bmatrix} = \begin{bmatrix} W_1' \\ W_2' \end{bmatrix}$$

这样输入和输出的关系就可以表示为

$$y = xW' = \begin{bmatrix} x_1 & x_2 \end{bmatrix} \begin{bmatrix} W_1' \\ W_2' \end{bmatrix} = [W_1'x_1 + W_2'x_2]$$

其中 W' 是新的参数。这个前向传播的算法完全符合线性模型的定义。从这个例子可以看到，虽然这个神经网络有两层（不算输入层），但是它和单层的神经网络并没有区别。以此类推，只通过线性变换，任意层的全连接神经网络和单层神经网络模型的表达能力没有任何区别，而且它们都是线性模型。然而线性模型能够解决的问题是有限的。这就是线性模型最大的局限性，也是为什么深度学习要强调非线性。在下面的篇幅中，将通过 TensorFlow 游乐场给出一个具体的例子来验证线性模型的局限性。

还是以判断零件是否合格为例，输入为 x_1 和 x_2 ，其中 x_1 代表一个零件质量和平均质量的差， x_2 代表一个零件长度和平均长度的差。假设一个零件的质量及长度离平均质量及长度越近，那么这个零件越有可能合格。于是训练数据很有可能服从图 4-1 所示的分布。




图 4-1 零件合格问题数据分布示意图

图 4-1 上黑色的点代表合格的零件，而灰色的点代表不合格的零件。可以看到虽然黑色和灰色的点有一些重合，但是大部分代表合格零件的黑色点都在原点(0,0)的附近，而代表不合格零件的灰点都在离原点相对远的地方。这样的分布比较接近真实问题，因为大部分真实的问题都存在大致的趋势，但是很难甚至无法完全正确地地区分不同的类别。图 4-2 显示了使用 TensorFlow 游乐场训练线性模型解决这个问题的效果。

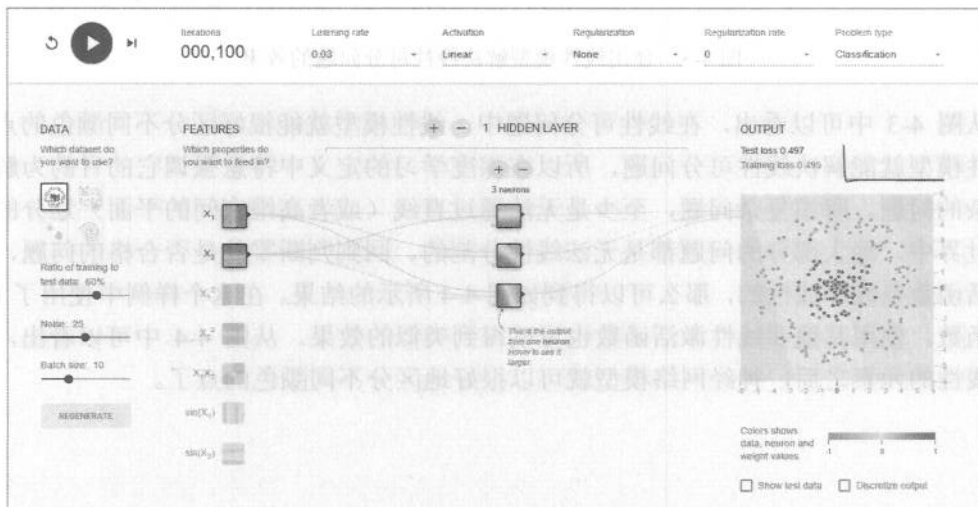


图 4-2 使用线性模型解决线性不可分问题的效果

图 4-2 使用的模型有一个隐藏层，并且在顶部激活函数^①（Activation）那一栏中选择了线性（Linear），这和 3.4.1 小节中介绍的神经网络结构是基本一致的。通过 TensorFlow 游乐场对这个模型训练 100 轮之后，在最右边那一栏可以看到训练的结果。从图 4-2 上可以看出，这个模型并不能很好的区分灰色的点和黑色的点。虽然整个平面的颜色都比较浅，但是中间还是隐约有一条分界线，这说明这个模型只能通过直线来划分平面。如果一个问题可以通过一条直线来划分，那么线性模型也是可以用来解决这个问题的。图 4-3 显示了一个可以通过直线划分的数据。

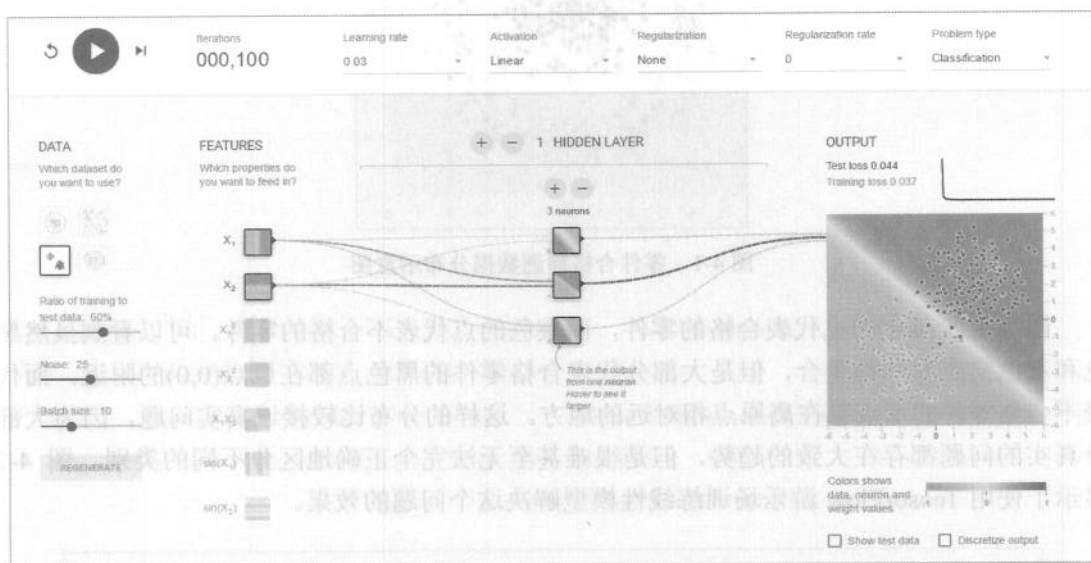


图 4-3 使用线性模型解决线性可分问题的效果

从图 4-3 中可以看出，在线性可分问题中，线性模型就能很好区分不同颜色的点。因为线性模型就能解决线性可分问题，所以在深度学习的定义中特意强调它的目的为解决更加复杂的问题。所谓复杂问题，至少是无法通过直线（或者高维空间的平面）划分的。在现实世界中，绝大部分的问题都是无法线性分割的。回到判断零件是否合格的问题，如果将激活函数换成非线性的，那么可以得到如图 4-4 所示的结果。在这个样例中使用了 ReLU 激活函数。使用其他非线性激活函数也可以得到类似的效果。从图 4-4 中可以看出，当加入非线性的元素之后，神经网络模型就可以很好地区分不同颜色的点了。

① 4.1.2 小节将详细介绍激活函数。

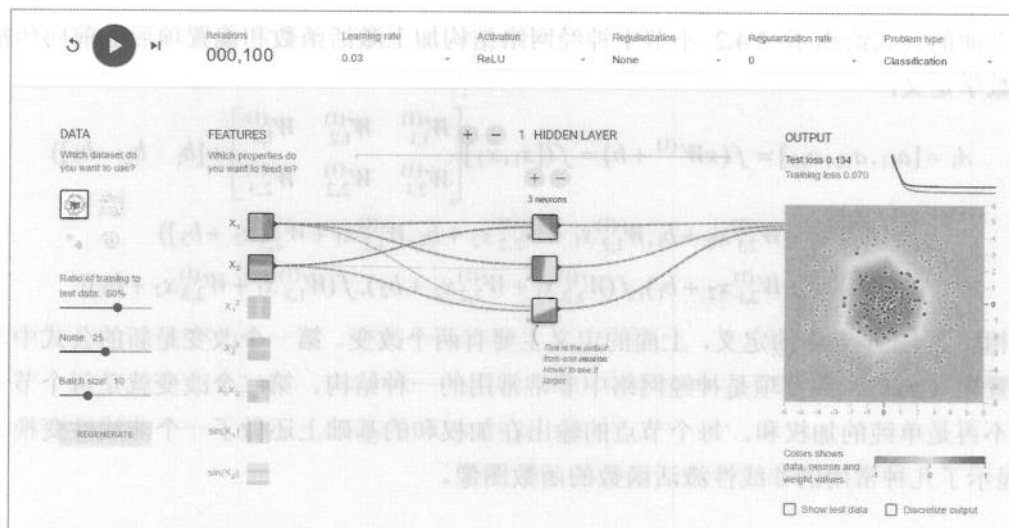


图 4-4 使用非线性模型解决线性不可分问题的效果

4.1.2 激活函数实现去线性化

4.1.1 小节已经提到过激活函数，并在样例中看到了它“神奇”的作用。在这一个小节中，将详细介绍激活函数是如何工作的。在 3.4.2 小节中介绍的神经元结构的输出为所有输入的加权和，这导致整个神经网络是一个线性模型。如果将每一个神经元（也就是神经网络中的节点）的输出通过一个非线性函数，那么整个神经网络的模型也就不再是线性的了。这个非线性函数就是激活函数。图 4-5 显示了加入激活函数和偏置项之后的神经元结构。




图 4-5 加入偏置项和激活函数的神经元结构示意图

下面的公式给出了 3.4.2 小节中神经网络结构加上激活函数和偏置项后的前向传播算法的数学定义:

$$\begin{aligned}
 A_1 &= [a_{11}, a_{12}, a_{13}] = f(xW^{(1)} + b) = f\left([x_1, x_2] \begin{bmatrix} W_{1,1}^{(1)} & W_{1,2}^{(1)} & W_{1,3}^{(1)} \\ W_{2,1}^{(1)} & W_{2,2}^{(1)} & W_{2,3}^{(1)} \end{bmatrix} + [b_1 \quad b_2 \quad b_3]\right) \\
 &= f([W_{1,1}^{(1)}x_1 + W_{2,1}^{(1)}x_2 + b_1, W_{1,2}^{(1)}x_1 + W_{2,2}^{(1)}x_2 + b_2, W_{1,3}^{(1)}x_1 + W_{2,3}^{(1)}x_2 + b_3]) \\
 &= [f(W_{1,1}^{(1)}x_1 + W_{2,1}^{(1)}x_2 + b_1), f(W_{1,2}^{(1)}x_1 + W_{2,2}^{(1)}x_2 + b_2), f(W_{1,3}^{(1)}x_1 + W_{2,3}^{(1)}x_2 + b_3)]
 \end{aligned}$$

相比 3.4.2 小节中的定义, 上面的定义主要有两个改变。第一个改变是新的公式中增加了偏置项 (bias), 偏置项是神经网络中非常常用的一种结构。第二个改变就是每个节点的取值不再是单纯的加权和。每个节点的输出在加权和的基础上还做了一个非线性变换。图 4-6 显示了几种常用的非线性激活函数的函数图像。




图 4-6 常用的神经网络激活函数的函数图像

从图 4-6 中可以看出, 这些激活函数的函数图像都不是一条直线。所以通过这些激活函数, 每一个节点不再是线性变换, 于是整个神经网络模型也就不再是线性的了。图 4-7 给出了加入偏置项和 ReLU 激活函数之后, 3.4.2 小节中神经网络的结构。

从图 4-7 中可以看出, 偏置项可以被表达为一个输出永远为 1 的节点。下面的公式给出了这个新的神经网络模型前向传播算法的计算方法。

隐藏层推导公式:

$$\begin{aligned}
 a_{11} &= f(W_{1,1}^{(1)}x_1 + W_{2,1}^{(1)}x_2 + b_1^{(1)}) = f(0.7 \times 0.2 + 0.9 \times 0.3 + (-0.5)) = f(-0.09) = 0.09 \\
 a_{12} &= f(W_{1,2}^{(1)}x_1 + W_{2,2}^{(1)}x_2 + b_2^{(1)}) = f(0.7 \times 0.1 + 0.9 \times (-0.5) \times 0.1) = f(-0.28) = 0.28 \\
 a_{13} &= f(W_{1,3}^{(1)}x_1 + W_{2,3}^{(1)}x_2 + b_3^{(1)}) = f(0.7 \times 0.4 + 0.9 \times 0.2 + (-0.1)) = f(0.36) = 0.36
 \end{aligned}$$

输出层推导公式:

$$Y = f(W_{1,1}^{(2)}a_{11} + W_{1,2}^{(2)}a_{12} + W_{1,3}^{(2)}a_{13} + b_1^{(2)}) = f(0.09 \times 0.6 + 0.28 \times 0.1 + 0.36 \times (-0.2) + 0.1) \\ = f(0.054 + 0.028 + (-0.072) + 0.1) = f(0.11) = 0.11$$




图 4-7 加入偏置项和激活函数的神经网络结构图

目前 TensorFlow 提供了 7 种不同的非线性激活函数，`tf.nn.relu`、`tf.sigmoid` 和 `tf.tanh` 是其中比较常用的几个。当然，TensorFlow 也支持使用自己定义的激活函数。以下代码展示了如何通过 TensorFlow 实现图 4-7 中神经网络的前向传播算法。

```
a = tf.nn.relu(tf.matmul(x, w1) + biases1)
y = tf.nn.relu(tf.matmul(a, w2) + biases2)
```

从上面的代码可以看出，TensorFlow 可以很好地支持使用了激活函数和偏置项的神经网络。

4.1.3 多层网络解决异或运算

上面的两个小节详细讲解了线性变换的问题。在这一小节中，将通过一个实际问题来讲解深度学习的另外一个重要性质——多层变换。在神经网络的发展史上，一个很重要的问题就是异或问题。神经网络的理论模型由 Warren McCulloch 和 Walter Pitts 在 1943 年首次提出，并在 1958 年由 Frank Rosenblatt 提出了感知机（perceptron）模型，从数学上完成了对神经网络的精确建模。感知机可以简单地理解为单层的神经网络，图 4-5 中给出的神经元结构就是感知机的网络结构。

感知机会先将输入进行加权和，然后再通过 4.1.2 小节中介绍的激活函数最后得到输出。这个结构就是一个没有隐藏层的神经网络。在上个世纪 60 年代，神经网络作为对人类大脑的模拟算法受到了很多关注。然而到了 1969 年，Marvin Minsky 和 Seymour Papert 在 *Perceptrons: An Introduction to Computational Geometry* 一书中提出感知机是无法模拟异或运算的^①。这里略去复杂的数学求证过程，而是通过 TensorFlow 游乐场来模拟一下通过感知机的网络结构来模拟异或运算。图 4-8 显示了通过 TensorFlow 游乐场训练 500 轮之后的情况。

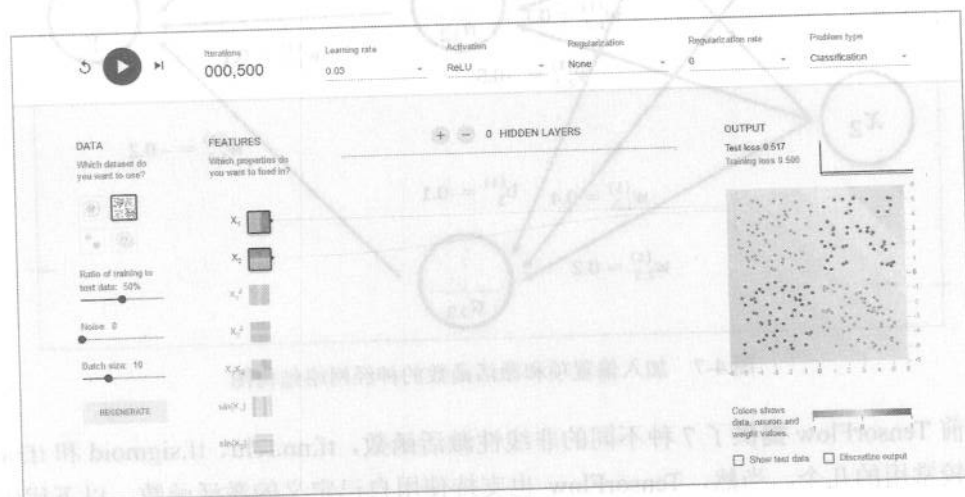


图 4-8 使用单层神经网络解决异或问题的效果图

图 4-8 使用了一个能够模拟异或运算的数据集。异或运算直观来说就是如果两个输入的符号相同时（同时为正或者同时为负）则输出为 0，否则（一个正一个负）输出为 1。从

^① 参见：Minsky, M.; S. Papert. *Perceptrons: An Introduction to Computational Geometry* [J]. MIT Press, 1969, ISBN 0-262-63022-2.

图 4-8 中可以看出, 左下角(两个输入同时为负)和右上角(两个输入同时为正)的点为黑色, 而另外两个象限的点为灰色, 这就符合异或运算的计算规则。图 4-8 中将隐藏层的层数设置为 0, 这样就模拟了感知机的模型。通过 500 轮训练之后, 可以看到这个感知机模型并不能将两种不同颜色的点分开, 也就是说感知机无法模拟异或运算的功能。

当加入隐藏层之后, 异或问题就可以得到很好地解决。图 4-9 显示了一个有 4 个节点的隐藏层的神经网络在训练 500 轮之后的效果。在图 4-9 中, 除了可以看到最右边的输出节点可以很好地区分不同颜色的点外, 更加有意思的是, 隐藏层的四个节点中, 每个节点都有一个角是黑色的。这四个隐藏节点可以被认为代表了从输入特征中抽取的更高维的特征。比如第一个节点可以大致代表两个输入的逻辑与操作的结果(当两个输入都为正数时该节点输出为正数)。从这个例子中可以看到, 深层神经网络实际上有组合特征提取的功能。这个特性对于解决不易提取特征向量的问题(比如图片识别、语音识别等)有很大帮助。这也是深度学习在这些问题上更加容易取得突破性进展的原因。

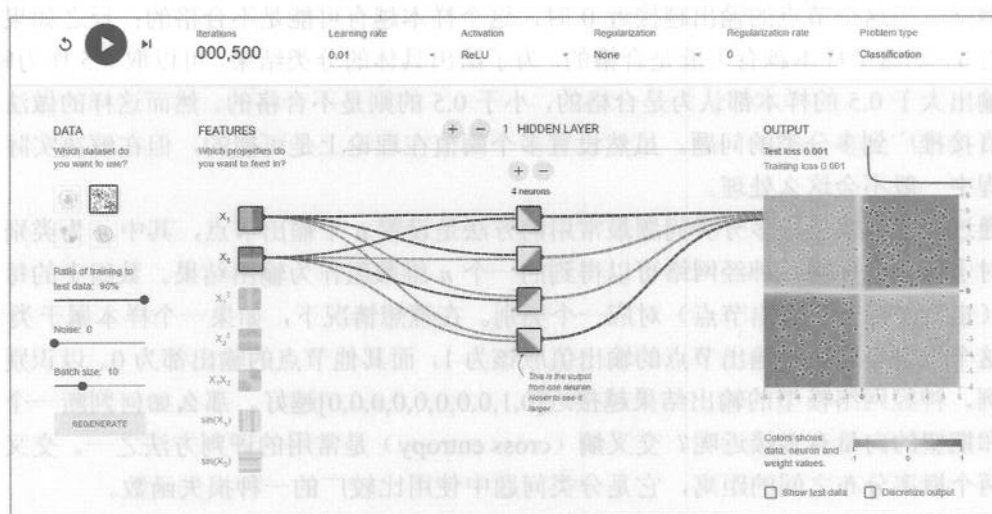


图 4-9 使用深层神经网络解决异或问题

4.2 损失函数定义

4.1 节介绍了深度学习的一些性质, 并且通过这些性质讲解了如何构造一个更加有效的神经网络。本节将具体介绍如何刻画不同神经网络模型的效果。神经网络模型的效果以及优化的目标是通过损失函数(loss function)来定义的。在 4.2.1 小节中, 将讲解适用于分类问题和回归问题的经典损失函数, 并通过 TensorFlow 实现这些损失函数。然后在 4.2.2 小节

中，将介绍如何根据具体问题定义损失函数，并通过具体样例来说明不同损失函数对训练结果的影响。

4.2.1 经典损失函数

分类问题和回归问题是监督学习的两大种类。这一小节将分别介绍分类问题和回归问题中使用到的经典损失函数。分类问题希望解决的是将不同的样本分到事先定义好的类别中。比如在第 3 章中介绍的判断一个零件是否合格的问题就是一个二分类问题。在这个问题中，需要将样本（也就是零件）分到合格或是不合格两个类别中。在 4.3 节中将要介绍的手写体数字识别问题可以被归纳成一个十分类问题。手写体数字识别问题可以被看成将一张包含了数字的图片分类到 0~9 这 10 个数字中。

在解决判断零件是否合格的二分类问题时，在第 3 章中定义过一个有单个输出节点的神经网络。当这个节点的输出越接近 0 时，这个样本越有可能是不合格的；反之如果输出越接近 1，则这个样本越有可能是合格的。为了给出具体的分类结果，可以取 0.5 作为阈值。凡是输出大于 0.5 的样本都认为是合格的，小于 0.5 的则是不合格的。然而这样的做法并不容易直接推广到多分类的问题。虽然设置多个阈值在理论上是可能的，但在解决实际问题的过程中一般不会这么处理。

通过神经网络解决多分类问题最常用的方法是设置 n 个输出节点，其中 n 为类别的个数。对于每一个样例，神经网络可以得到的一个 n 维数组作为输出结果。数组中的每一个维度（也就是每一个输出节点）对应一个类别。在理想情况下，如果一个样本属于类别 k ，那么这个类别所对应的输出节点的输出值应该为 1，而其他节点的输出都为 0。以识别数字 1 为例，神经网络模型的输出结果越接近 $[0, 1, 0, 0, 0, 0, 0, 0, 0]$ 越好。那么如何判断一个输出向量和期望的向量有多接近呢？交叉熵（cross entropy）是常用的评判方法之一。交叉熵刻画了两个概率分布之间的距离，它是分类问题中使用比较广的一种损失函数。

交叉熵是一个信息论中的概念，它原本是用来估算平均编码长度的。在本书中不过多讨论它原本的意义，而会通过它的公式以及具体的样例来讲解它对于评估分类效果的意义。给定两个概率分布 p 和 q ，通过 q 来表示 p 的交叉熵为：

$$H(p, q) = -\sum_x p(x) \log q(x)$$

注意交叉熵刻画的是两个概率分布之间的距离，然而神经网络的输出却不一定是一个概率分布。概率分布刻画了不同事件发生的概率。当事件总数是有限的情况下，概率分布函数 $p(X=x)$ 满足：

$$\forall x \quad p(X=x) \in [0, 1] \text{ 且 } \sum_x p(X=x) = 1$$

也就是说,任意事件发生的概率都在 0 和 1 之间,且总有某一个事件发生(概率的和为 1)。如果将分类问题中“一个样例属于某一个类别”看成一个概率事件,那么训练数据的正确答案就符合一个概率分布。因为事件“一个样例属于不正确的类别”的概率为 0,而“一个样例属于正确的类别”的概率为 1。如何将神经网络前向传播得到的结果也变成概率分布呢? Softmax 回归就是一个非常常用的方法。

Softmax 回归本身可以作为一个学习算法来优化分类结果,但在 TensorFlow 中,Softmax 回归的参数被去掉了,它只是一层额外的处理层,将神经网络的输出变成一个概率分布。图 4-10 展示了加上了 Softmax 回归的神经网络结构图。




图 4-10 通过 Softmax 层将神经网络输出变成一个概率分布

假设原始的神经网络输出为 y_1, y_2, \dots, y_n , 那么经过 Softmax 回归处理之后的输出为:

$$\text{softmax}(y)_i = y'_i = \frac{e^{y_i}}{\sum_{j=1}^n e^{y_j}}$$

从以上公式中可以看出,原始神经网络的输出被用作置信度来生成新的输出,而新的输出满足概率分布的所有要求。这个新的输出可以理解为经过神经网络的推导,一个样例为不同类别的概率分别是多大。这样就把神经网络的输出也变成了一个概率分布,从而可以通过交叉熵来计算预测的概率分布和真实答案的概率分布之间的距离了。

从交叉熵的公式中可以看到交叉熵函数不是对称的 ($H(p, q) \neq H(q, p)$), 它刻画的是通过概率分布 q 来表达概率分布 p 的困难程度。因为正确答案是希望得到的结果,所以当交叉熵作为神经网络的损失函数时, p 代表的是正确答案, q 代表的是预测值。交叉熵刻画的是两个概率分布的距离,也就是说交叉熵值越小,两个概率分布越接近。下面将给出两个具体样例来直观地说明通过交叉熵可以判断预测答案和真实答案之间的距离。假设有一

个三分类问题，某个样例的正确答案是 (1,0,0)。某模型经过 Softmax 回归之后的预测答案是 (0.5,0.4,0.1)，那么这个预测和正确答案之间的交叉熵为：

$$H((1,0,0),(0.5,0.4,0.1)) = -(1 \times \log 0.5 + 0 \times \log 0.4 + 0 \times \log 0.1) \approx 0.3$$

如果另外一个模型的预测是 (0.8,0.1,0.1)，那么这个预测值和真实值之间的交叉熵是：

$$H((1,0,0),(0.8,0.1,0.1)) = -(1 \times \log 0.8 + 0 \times \log 0.1 + 0 \times \log 0.1) \approx 0.1$$

从直观上可以很容易地知道第二个预测答案要优于第一个。通过交叉熵计算得到的结果也是一致的（第二个交叉熵的值更小）。在 3.4.5 小节中，已经通过 TensorFlow 实现过交叉熵，其代码实现如下：

```
cross_entropy = -tf.reduce_mean(
    y_ * tf.log(tf.clip_by_value(y, 1e-10, 1.0)))
```

其中 $y_$ 代表正确结果， y 代表预测结果。本小节将更加具体的讲解这个计算过程。这一行代码包含了四个不同的 TensorFlow 运算。通过 `tf.clip_by_value` 函数可以将一个张量中的数值限制在一个范围之内，这样可以避免一些运算错误（比如 $\log 0$ 是无效的）。下面给出了使用 `tf.clip_by_value` 的简单样例。

```
v = tf.constant([[1.0, 2.0, 3.0], [4.0, 5.0, 6.0]])
print tf.clip_by_value(v, 2.5, 4.5).eval()
# 输出 [[ 2.5  2.5  3.] [ 4.  4.5  4.5]]
```

在上面的样例中可以看到，小于 2.5 的数都被换成了 2.5，而大于 4.5 的数都被换成了 4.5。这样通过 `tf.clip_by_value` 函数就可以保证在进行 \log 运算时，不会出现 $\log 0$ 这样的错误或者大于 1 的概率。第二个运算是 `tf.log` 函数，这个函数完成了对张量中所有元素依次求对数的功能。以下代码中给出一个简单的样例。

```
v = tf.constant([1.0, 2.0, 3.0])
print tf.log(v).eval()
# 输出 [ 0.    0.69314718  1.09861231]
```

第三个运算是乘法，在实现交叉熵的代码中直接将两个矩阵通过 “*” 操作相乘。这个操作不是矩阵乘法，而是元素之间直接相乘。矩阵乘法需要使用 `tf.matmul` 函数来完成。下面给出了这两个操作的区别：

```
v1 = tf.constant([[1.0, 2.0], [3.0, 4.0]])
v2 = tf.constant([[5.0, 6.0], [7.0, 8.0]])

print (v1 * v2).eval()
# 输出 [[ 5.  12.] [ 21.  32.]]

print tf.matmul(v1, v2).eval()
# 输出 [[ 19.  22.] [ 43.  50.]]
```

$v1*v2$ 的结果是每个位置上对应元素的乘积。比如 (1,1) 这个元素的值是：

$$v1[1,1] \times v2[1,1] = 1 \times 5 = 5$$

(1,2) 这个元素的值是：

$$v1[1,2] \times v2[1,2] = 2 \times 6 = 12$$

以此类推。而 `tf.matmul` 函数完成的是矩阵乘法运算，所以 (1,1) 这个元素的值是：

$$v1[1,1] \times v2[1,1] + v1[1,2] \times v2[2,1] = 1 \times 5 + 2 \times 7 = 19$$

通过上面这三个运算完成了对于每一个样例中的每一个类别交叉熵 $p(x) \log q(x)$ 的计算。这三步计算得到的结果是一个 $n \times m$ 的二维矩阵，其中 n 为一个 batch 中样例的数量， m 为分类的类别数量。根据交叉熵的公式，应该将每行中的 m 个结果相加得到所有样例的交叉熵，然后再对这 n 行取平均得到一个 batch 的平均交叉熵。但因为分类问题的类别数量是不变的，所以可以直接对整个矩阵做平均而并不改变计算结果的意义。这样的方式可以使整个程序更加简洁。以下代码简单展示了 `tf.reduce_mean` 函数的使用方法。

```
v = tf.constant([[1.0, 2.0, 3.0], [4.0, 5.0, 6.0]])
print tf.reduce_mean(v).eval() # 输出 3.5
```

因为交叉熵一般会与 softmax 回归一起使用，所以 TensorFlow 对这两个功能进行了统一封装，并提供了 `tf.nn.softmax_cross_entropy_with_logits` 函数。比如可以直接通过下面的代码来实现使用了 softmax 回归之后的交叉熵损失函数：

```
cross_entropy = tf.nn.softmax_cross_entropy_with_logits(y, y_)
```

其中 y 代表了原始神经网络的输出结果，而 $y_$ 给出了标准答案。这样通过一个命令就可以得到使用了 Softmax 回归之后的交叉熵。在只有一个正确答案的分类问题中，TensorFlow 提供了 `tf.nn.sparse_softmax_cross_entropy_with_logits` 函数来进一步加速计算过程。在第 5 章中将提供使用这个函数的完整样例。

与分类问题不同，回归问题解决的是对具体数值的预测。比如房价预测、销量预测等都是回归问题。这些问题需要预测的不是一个事先定义好的类别，而是一个任意实数。解决回归问题的神经网络一般只有一个输出节点，这个节点的输出值就是预测值。对于回归问题，最常用的损失函数是均方误差 (MSE, mean squared error)^①。它的定义如下：

$$MSE(y, y') = \frac{\sum_{i=1}^n (y_i - y'_i)^2}{n}$$

其中 y_i 为一个 batch 中第 i 个数据的正确答案，而 y'_i 为神经网络给出的预测值。以下代码展示了如何通过 TensorFlow 实现均方误差损失函数：

```
mse = tf.reduce_mean(tf.square(y_ - y))
```

① 均方误差也是分类问题中常用的一种损失函数。

其中 y 代表了神经网络的输出答案, y_* 代表了标准答案。类似 4.2.1 小节中介绍的乘法操作, 这里的减法运算 “-” 也是两个矩阵中对应元素的减法。

4.2.2 自定义损失函数

TensorFlow 不仅支持经典的损失函数, 还可以优化任意的自定义损失函数。本小节将介绍如何通过自定义损失函数的方法, 使得神经网络优化的结果更加接近实际需求。在下面的篇幅中将以预测商品销量问题为例。

在预测商品销量时, 如果预测多了 (预测值比真实销量大), 商家损失的是生产商品的成本; 而如果预测少了 (预测值比真实销量小), 损失的则是商品的利润。因为一般商品的成本和商品的利润不会严格相等, 所以使用 4.2.1 小节中介绍的均方误差损失函数就不能够很好地最大化销售利润。比如如果一个商品的成本是 1 元, 但是利润是 10 元, 那么少预测一个就少挣 10 元; 而多预测一个才少挣 1 元。如果神经网络模型最小化的是均方误差, 那么很有可能此模型就无法最大化预期的利润。为了最大化预期利润, 需要将损失函数和利润直接联系起来。注意损失函数定义的是损失, 所以要将利润最大化, 定义的损失函数应该刻画成本或者代价。下面的公式给出了一个当预测多于真实值和预测少于真实值时有不同损失系数的损失函数:

$$\text{Loss}(y, y') = \sum_{i=1}^n f(y_i, y'_i), \quad f(x, y) = \begin{cases} a(x - y) & x > y \\ b(y - x) & x \leq y \end{cases}$$

和均方误差公式类似, y_i 为一个 batch 中第 i 个数据的正确答案, y'_i 为神经网络得到的预测值, a 和 b 是常量。比如在上面介绍的销量预测问题中, a 就等于 10 (正确答案多于预测答案的代价), 而 b 等于 1 (正确答案少于预测答案的代价)。通过对这个自定义损失函数的优化, 模型提供的预测值更有可能最大化收益。在 TensorFlow 中, 可以通过以下代码来实现这个损失函数。

```
loss = tf.reduce_sum(tf.select(tf.greater(v1, v2),
                                (v1 - v2) * a, (v2 - v1) * b))
```

上面的代码用到了 `tf.greater` 和 `tf.select` 来实现选择操作。`tf.greater` 的输入是两个张量, 此函数会比较这两个输入张量中每一个元素的大小, 并返回比较结果。当 `tf.greater` 的输入张量维度不一样时, TensorFlow 会进行类似 NumPy 广播操作 (broadcasting) 的处理^①。`tf.select` 函数有三个参数。第一个为选择条件根据, 当选择条件为 `True` 时, `tf.select` 函数会选择第二个参数中的值, 否则使用第三个参数中的值。注意 `tf.select` 函数判断和选择都是在元素级

^① <http://docs.scipy.org/doc/numpy/user/basics.broadcasting.html> 中有关于广播操作 (broadcasting) 的具体讲解。

别进行，以下代码展示了 `tf.select` 函数和 `tf.greater` 函数的用法。

```
import tensorflow as tf
v1 = tf.constant([1.0, 2.0, 3.0, 4.0])
v2 = tf.constant([4.0, 3.0, 2.0, 1.0])

sess = tf.InteractiveSession()
print tf.greater(v1, v2).eval()
# 输出[False False True True]

print tf.select(tf.greater(v1, v2), v1, v2).eval()
# 输出[4. 3. 3. 4.]
sess.close()
```

在定义了损失函数之后，下面将通过一个简单的神经网络程序来讲解损失函数对模型训练结果的影响。在下面这个程序中，实现了一个拥有两个输入节点、一个输出节点，没有隐藏层的神经网络。这个程序的主体流程和 3.4.5 小节中给出来的样例基本一致，但用到了上面定义的损失函数。

```
import tensorflow as tf
from numpy.random import RandomState

batch_size = 8

# 两个输入节点。
x = tf.placeholder(tf.float32, shape=(None, 2), name='x-input')
# 回归问题一般只有一个输出节点。
y_ = tf.placeholder(tf.float32, shape=(None, 1), name='y-input')

# 定义了一个单层的神经网络前向传播的过程，这里就是简单加权和。
w1 = tf.Variable(tf.random_normal([2, 1], stddev=1, seed=1))
y = tf.matmul(x, w1)

# 定义预测多了和预测少了的成本。
loss_less = 10
loss_more = 1
loss = tf.reduce_sum(tf.select(tf.greater(y, y_),
                               (y - y_) * loss_more,
                               (y_ - y) * loss_less))

train_step = tf.train.AdamOptimizer(0.001).minimize(loss)

# 通过随机数生成一个模拟数据集。
rdm = RandomState(1)
```

```

dataset_size = 128
X = rdm.rand(dataset_size, 2)
# 设置回归的正确值为两个输入的和加上一个随机量。之所以要加上一个随机量是为了
# 加入不可预测的噪音，否则不同损失函数的意义就不大了，因为不同损失函数都会在能
# 完全预测正确的时候最低。一般来说噪音为一个均值为 0 的小量，所以这里的噪音设置为
# -0.05 ~ 0.05 的随机数。
Y = [[x1 + x2 + rdm.rand()/10.0-0.05] for (x1, x2) in X]

# 训练神经网络。
with tf.Session() as sess:
    init_op = tf.initialize_all_variables()
    sess.run(init_op)
    STEPS = 5000
    for i in range(STEPS):
        start = (i * batch_size) % dataset_size
        end = min(start+batch_size, dataset_size)
        sess.run(train_step,
                  feed_dict={x: X[start:end], y: Y[start:end]})
    print sess.run(w1)

```

运行上面的代码会得到 w_1 的值为 $[1.01934695, 1.04280889]$ ，也就是说得到的预测函数是 x_1+x_2 ，这要比 $1.02x_1+1.04x_2$ 大，因为在损失函数中指定预测少了的损失更大 ($\text{loss_less} > \text{loss_more}$)。如果将 loss_less 的值调整为 1， loss_more 的值调整为 10，那么 w_1 的值将会是 $[0.95525807, 0.9813394]$ 。也就是说，在这样的设置下，模型会更加偏向于预测少一点。而如果使用均方误差作为损失函数，那么 w_1 会是 $[0.97437561, 1.0243336]$ 。使用这个损失函数会尽量让预测值离标准答案更近。通过这个样例可以感受到，对于相同的神经网络，不同的损失函数会对训练得到的模型产生重要影响。

4.3 神经网络优化算法

本节将更加具体地介绍如何通过反向传播算法 (backpropagation) 和梯度下降算法 (gradient decent) 调整神经网络中参数的取值。梯度下降算法主要用于优化单个参数的取值，而反向传播算法给出了一个高效的方式在所有参数上使用梯度下降算法，从而使神经网络模型在训练数据上的损失函数尽可能小。反向传播算法是训练神经网络的核心算法，它可以根据定义好的损失函数优化神经网络中参数的取值，从而使神经网络模型在训练数据集上的损失函数达到一个较小值。神经网络模型中参数的优化过程直接决定了模型的质量，是使用神经网络时非常重要的一步。在本节中，将主要介绍神经网络优化过程的基本概念

和主要思想，而略去算法的数学推导和证明^①。本节将给出一个具体的样例来解释使用梯度下降算法优化参数取值的过程。在下面的 4.4 节中，将继续介绍的神经网络优化过程中可能遇到的问题和解决方法，掌握本节内容可以帮助更好地理解这些优化方法。

假设用 θ 表示神经网络中的参数， $J(\theta)$ 表示在给定的参数取值下，训练数据集上损失函数的大小，那么整个优化过程可以抽象为寻找一个参数 θ ，使得 $J(\theta)$ 最小。因为目前没有一个通用的方法可以对任意损失函数直接求解最佳的参数取值，所以在实践中，梯度下降算法是最常用的神经网络优化方法。梯度下降算法会迭代式更新参数 θ ，不断沿着梯度的反方向让参数朝着总损失更小的方向更新。图 4-11 展示了梯度下降算法的原理。




图 4-11 梯度下降算法思想示意图

图 4-11 中 x 轴表示参数 θ 的取值， y 轴表示损失函数 $J(\theta)$ 的值。图 4-11 的曲线表示了参数 θ 取不同值时，对应损失函数 $J(\theta)$ 的大小。假设当前的参数和损失值对应图 4-11 中小圆点的位置，那么梯度下降算法会将参数向 x 轴左侧移动，从而使得小圆点朝着箭头的方向移动。参数的梯度可以通过求偏导的方式计算，对于参数 θ ，其梯度为 $\frac{\partial}{\partial \theta} J(\theta)$ 。有了梯度，还需要定义一个学习率 η ^② (learning rate) 来定义每次参数更新的幅度。从直观上理解，可以认为学习率定义的就是每次参数移动的幅度。通过参数的梯度和学习率，参数更新的公式为：

$$\theta_{n+1} = \theta_n - \eta \frac{\partial}{\partial \theta_n} J(\theta_n)$$

下面给出了一个具体的例子来说明梯度下降算法是如何工作的。假设要通过梯度下降

① 更多关于反向传播算法的细节可以参见：Rumelhart D E, Hinton G E, Williams R J. *Learning representations by back-propagating errors* [M]Neurocomputing: foundations of research. MIT Press, 1986。

② 学习率的设置将在 4.4.1 小节中详细介绍。

算法来优化参数 x ，使得损失函数 $J(x)=x^2$ 的值尽量小。梯度下降算法的第一步需要随机产生一个参数 x 的初始值，然后再通过梯度和学习率来更新参数 x 的取值。在这个样例中，参数 x 的梯度为 $\nabla = \frac{\partial J(x)}{\partial x} = 2x$ ，那么使用梯度下降算法每次对参数 x 的更新公式为 $x_{n+1} = x_n - \eta \nabla n$ 。假设参数的初始值为 5，学习率为 0.3，那么这个优化过程可以总结为表 4-1。

表 4-1 使用梯度下降算法优化函数 $J(x) = x^2$

轮数	当前轮参数值	梯度×学习率	更新后参数值
1	5	$2 \times 5 \times 0.3 = 3$	$5 - 3 = 2$
2	2	$2 \times 2 \times 0.3 = 1.2$	$2 - 1.2 = 0.8$
3	0.8	$2 \times 0.8 \times 0.3 = 0.48$	$0.8 - 0.48 = 0.32$
4	0.32	$2 \times 0.32 \times 0.3 = 0.192$	$0.32 - 0.192 = 0.128$
5	0.128	$2 \times 0.128 \times 0.3 = 0.0768$	$0.128 - 0.0768 = 0.0512$

从表 4-1 中可以看出，经过 5 次迭代之后，参数 x 的值变成了 0.0512，这个和参数最优值 0 已经比较接近了。虽然这里给出的是一个非常简单的样例，但是神经网络的优化过程也是可以类推的。神经网络的优化过程可以分为两个阶段，第一个阶段先通过前向传播算法计算得到预测值，并将预测值和真实值做对比得出两者之间的差距。然后在第二个阶段通过反向传播算法计算损失函数对每一个参数的梯度，再根据梯度和学习率使用梯度下降算法更新每一个参数。本书将略去反向传播算法具体的实现方法和数学证明，有兴趣的读者可以参考 David Rumelhart、Geoffrey Hinton 和 Ronald Williams 教授发表的论文 *Learning representations by back-propagating errors*^①。

需要注意的是，梯度下降算法并不能保证被优化的函数达到全局最优解。如图 4-12 所示，图中给出的函数就有可能只能得到局部最优解而不是全局最优解。在小黑点处，损失函数的偏导为 0，于是参数就不会再进一步更新。在这个样例中，如果参数 x 的初始值落在右侧深色的区间中，那么通过梯度下降得到的结果都会落到小黑点代表的局部最优解。只有当 x 的初始值落在左侧浅色的区间时梯度下降才能给出全局最优答案。由此可见在训练神经网络时，参数的初始值会很大程度影响最后得到的结果。只有当损失函数为凸函数时，梯度下降算法才能保证达到全局最优解。

① Rumelhart D E, Hinton G E, Williams R J. *Learning representations by back-propagating errors* [M]. Neurocomputing: foundations of research. MIT Press, 1986.




图 4-12 梯度下降算法得不到全局最小值的样例

除了不一定能达到全局最优外，梯度下降算法的另外一个问题就是计算时间太长。因为要在全部训练数据上最小化损失，所以损失函数 $J(\theta)$ 是在所有训练数据上的损失和。这样在每一轮迭代中都需要计算在全部训练数据上的损失函数。在海量训练数据下，要计算所有训练数据的损失函数是非常消耗时间的。为了加速训练过程，可以使用随机梯度下降的算法（stochastic gradient descent）。这个算法优化的不是在全部训练数据上的损失函数，而是在每一轮迭代中，随机优化某一条训练数据上的损失函数。这样每一轮参数更新的速度就大大加快了。因为随机梯度下降算法每次优化的只是某一条数据上的损失函数，所以它的问题也非常明显：在某一条数据上损失函数更小并不代表在全部数据上损失函数更小，于是使用随机梯度下降优化得到的神经网络甚至可能无法达到局部最优。

为了综合梯度下降算法和随机梯度下降算法的优缺点，在实际应用中一般采用这两个算法的折中——每次计算一小部分训练数据的损失函数。这一小部分数据被称之为一个 batch。通过矩阵运算，每次在一个 batch 上优化神经网络的参数并不会比单个数据慢太多。另一方面，每次使用一个 batch 可以大大减小收敛所需要的迭代次数，同时可以使收敛到的结果更加接近梯度下降的效果。以下代码给出了在 TensorFlow 中如何实现神经网络的训练过程。在本书的所有样例中，神经网络的训练都大致遵循以下过程。

```
batch_size = n

# 每次读取一小部分数据作为当前的训练数据来执行反向传播算法。
x = tf.placeholder(tf.float32, shape=(batch_size, 2), name='x-input')
y_ = tf.placeholder(tf.float32, shape=(batch_size, 1), name='y-input')

# 定义神经网络结构和优化算法。
loss = ...
train_step = tf.train.AdamOptimizer(0.001).minimize(loss)

# 训练神经网络。
with tf.Session() as sess:
    # 参数初始化。
    ...
```

```
# 迭代的更新参数。
for i in range(STEPS):
    # 准备 batch_size 个训练数据。一般将所有训练数据随机打乱之后再选取可以得到
    # 更好的优化效果。
    current_X, current_Y = ...
    sess.run(train_step, feed_dict={x: current_X, y: current_Y})
```

4.4 神经网络进一步优化

4.3 节介绍了优化神经网络的基本算法，本节将继续介绍神经网络优化过程中可能遇到的一些问题，以及解决这些问题的常用方法。4.4.1 小节将介绍通过指数衰减的方法设置梯度下降算法中的学习率。通过指数衰减的学习率即可以让模型在训练的前期快速接近较优解，又可以保证模型在训练后期不会有太大的波动，从而更加接近局部最优。然后 4.4.2 小节将介绍过拟合问题。在训练复杂神经网络模型时，过拟合是一个非常常见的问题。这一小节将具体介绍这个问题的影响以及解决这个问题的主要方法。最后 4.4.3 小节将介绍滑动平均模型。滑动平均模型会将每一轮迭代得到的模型综合起来，从而使得最终得到的模型更加健壮 (robust)。

4.4.1 学习率的设置

4.3 节介绍了在训练神经网络时，需要设置学习率 (learning rate) 控制参数更新的速度。本小节将进一步介绍如何设置学习率。学习率决定了参数每次更新的幅度。如果幅度过大，那么可能导致参数在极优值的两侧来回移动。4.3 节介绍过优化 $J(x) = x^2$ 函数的样例。如果在优化中使用的学习率为 1，那么整个优化过程将会如表 4-2 所示。

表 4-2 当学习率过大时，梯度下降算法的运行过程

轮数	当前轮参数值	梯度×学习率	更新后参数值
1	5	$2 \times 5 \times 1 = 10$	$5 - 10 = -5$
2	-5	$2 \times (-5) \times 1 = -10$	$-5 - (-10) = 5$
3	5	$2 \times 5 \times 1 = 10$	$5 - 10 = -5$

从上面的样例可以看出，无论进行多少轮迭代，参数将在 5 和 -5 之间摇摆，而不会收敛到一个极小值。相反，当学习率过小时，虽然能保证收敛性，但是这会大大降低优化速度。我们会需要更多轮的迭代才能达到一个比较理想的优化效果。比如当学习率为 0.001 时，迭代 5 次之后， x 的值将为 4.95。要将 x 训练到 0.05 需要大约 2300 轮；而当学习率为 0.3 时，只需要 5 轮就可以达到。综上所述，学习率既不能过大，也不能过小。为了解决设

定学习率的问题，TensorFlow 提供了一种更加灵活的学习率设置方法——指数衰减法。`tf.train.exponential_decay` 函数实现了指数衰减学习率。通过这个函数，可以先使用较大的学习率来快速得到一个比较优的解，然后随着迭代的继续逐步减小学习率，使得模型在训练后期更加稳定。`exponential_decay` 函数会指数级地减小学习率，它实现了以下代码的功能：

```
decayed_learning_rate = \
    learning_rate * decay_rate ^ (global_step / decay_steps)
```

其中 `decayed_learning_rate` 为每一轮优化时使用的学习率，`learning_rate` 为事先设定的初始学习率，`decay_rate` 为衰减系数，`decay_steps` 为衰减速度。图 4-13 显示了随着迭代轮数的增加，学习率逐步降低的过程。`tf.train.exponential_decay` 函数可以通过设置参数 `staircase` 选择不同的衰减方式。`staircase` 的默认值为 `False`，这时学习率随迭代轮数变化的趋势如图 4-13 中灰色曲线所示。当 `staircase` 的值被设置为 `True` 时，`global_step / decay_steps` 会被转化成整数。这使得学习率成为一个阶梯函数（`staircase function`）。图 4-13 中黑色曲线显示了阶梯状的学习率。在这样的设置下，`decay_steps` 通常代表了完整的使用一遍训练数据所需要的迭代轮数。这个迭代轮数也就是总训练样本数除以每一个 `batch` 中的训练样本数。这种设置的常用场景是每完整地过完一遍训练数据，学习率就减小一次。这可以使得训练数据集中的所有数据对模型训练有相等的作用。当使用连续的指数衰减学习率时，不同的训练数据有不同的学习率，而当学习率减小时，对应的训练数据对模型训练结果的影响也就小了。下面给出了一段代码来示范如何在 TensorFlow 中使用 `tf.train.exponential_decay` 函数。




图 4-13 指数衰减学习率随着迭代轮数的变化图
(图中使用的基础学习率为 0.1，衰减率为 0.9，衰减速度为 50)

```
global_step = tf.Variable(0)

# 通过 exponential_decay 函数生成学习率。
learning_rate = tf.train.exponential_decay(
    0.1, global_step, 100, 0.96, staircase=True)

# 使用指数衰减的学习率。在 minimize 函数中传入 global_step 将自动更新
# global_step 参数，从而使得学习率也得到相应更新。
learning_step = tf.train.GradientDescentOptimizer(learning_rate)\
    .minimize(...my loss..., global_step=global_step)
```

上面这段代码中设定了初始学习率为 0.1，因为指定了 `staircase=True`，所以每训练 100 轮后学习率乘以 0.96。一般来说初始学习率、衰减系数和衰减速度都是根据经验设置的。而且损失函数下降的速度和迭代结束之后总损失的大小没有必然的联系。也就是说并不能通过前几轮损失函数下降的速度来比较不同神经网络的效果。

4.4.2 过拟合问题

上面的 4.2 和 4.3 节讲述了如何在训练数据上优化一个给定的损失函数。然而在真实的应用中想要的并不是让模型尽量模拟训练数据的行为，而是希望通过训练出来的模型对未知的数据给出判断。模型在训练数据上的表现并不一定代表了它在未知数据上的表现。本小节将介绍的过拟合问题就是可以导致这个差距的一个很重要因素。所谓过拟合，指的是当一个模型过为复杂之后，它可以很好地“记忆”每一个训练数据中随机噪音的部分而忘记了要去“学习”训练数据中通用的趋势。举一个极端的例子，如果一个模型中的参数比训练数据的总数还多，那么只要训练数据不冲突，这个模型完全可以记住所有训练数据的结果从而使得损失函数为 0。可以直观地想象一个包含 n 个变量和 n 个等式的方程组，当方程不冲突时，这个方程组是可以通过数学的方法来求解的。然而，过度拟合训练数据中的随机噪音虽然可以得到非常小的损失函数，但是对于未知数据可能无法做出可靠的判断。

图 4-14 显示了模型训练的三种不同情况。在第一种情况下，由于模型过于简单，无法刻画问题的趋势。第二个模型是比较合理的，它既不会过于关注训练数据中的噪音，又能够比较好地刻画问题的整体趋势。第三个模型就是过拟合了，虽然第三个模型完美地划分了不同形状的点，但是这样的划分并不能很好地对未知数据做出判断，因为它过度拟合了训练数据中的噪音而忽视了问题的整体规律。比如图中浅色方框“□”更有可能和“X”属于同一类，而不是根据图上的划分和“O”属于同一类。

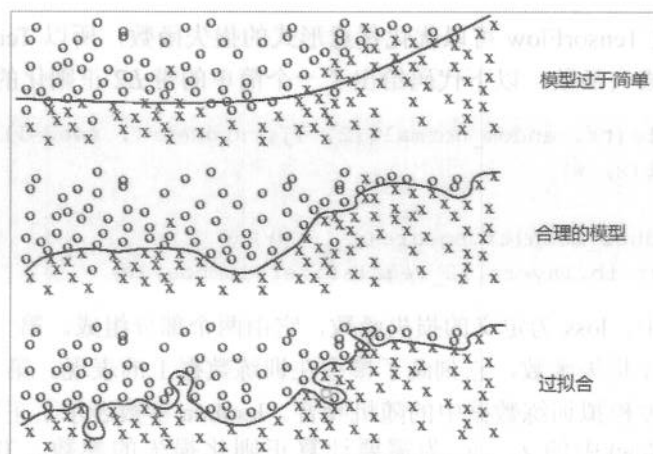


图 4-14 神经网络模型训练的三种情况

为了避免过拟合问题，一个非常常用的方法是正则化（regularization）。正则化的思想就是在损失函数中加入刻画模型复杂程度的指标。假设用于刻画模型在训练数据上表现的损失函数为 $J(\theta)$ ，那么在优化时不是直接优化 $J(\theta)$ ，而是优化 $J(\theta) + \lambda R(w)$ 。其中 $R(w)$ 刻画的是模型的复杂程度，而 λ 表示模型复杂损失在总损失中的比例。注意这里 θ 表示的是一个神经网络中所有的参数，它包括边上的权重 w 和偏置项 b 。一般来说模型复杂度只由权重 w 决定。常用的刻画模型复杂度的函数 $R(w)$ 有两种，一种是 $L1$ 正则化，计算公式是：

$$R(w) = \|w\|_1 = \sum_i |w_i|$$

另一种是 $L2$ 正则化，计算公式是：

$$R(w) = \|w\|_2^2 = \sum_i |w_i|^2$$

无论是哪一种正则化方式，基本的思想都是希望通过限制权重的大小，使得模型不能任意拟合训练数据中的随机噪音。但这两种正则化的方法也有很大的区别。首先， $L1$ 正则化会让参数变得更稀疏，而 $L2$ 正则化不会。所谓参数变得更稀疏是指会有更多的参数变为 0，这样可以达到类似特征选取的功能。之所以 $L2$ 正则化不会让参数变得稀疏的原因是当参数很小时，比如 0.001，这个参数的平方基本上就可以忽略了，于是模型不会进一步将这个参数调整为 0。其次， $L1$ 正则化的计算公式不可导，而 $L2$ 正则化公式可导。因为在优化时需要计算损失函数的偏导数，所以对含有 $L2$ 正则化损失函数的优化要更加简洁。优化带 $L1$ 正则化的损失函数要更加复杂，而且优化方法也有很多种。在实践中，也可以将 $L1$ 正则化和 $L2$ 正则化同时使用：

$$R(w) = \sum_i \alpha |w_i| + (1 - \alpha) w_i^2$$

4.2 小节提到过 TensorFlow 可以优化任意形式的损失函数，所以 TensorFlow 自然也可以优化带正则化的损失函数。以下代码给出了一个简单的带 $L2$ 正则化的损失函数定义：

```
w = tf.Variable(tf.random_normal([2, 1], stddev=1, seed=1))
y = tf.matmul(x, w)

loss = tf.reduce_mean(tf.square(y_ - y)) +
      tf.contrib.layers.l2_regularizer(lambda)(w)
```

在上面的程序中，loss 为定义损失函数，它由两个部分组成。第一个部分是 4.2.1 小节中介绍的均方误差损失函数，它刻画了模型在训练数据上的表现。第二个部分就是正则化，它防止模型过度模拟训练数据中的随机噪音。lambda 参数表示了正则化项的权重，也就是公式 $J(\theta) + \lambda R(w)$ 中的 λ 。w 为需要计算正则化损失的参数。TensorFlow 提供了 tf.contrib.layers.l2_regularizer 函数，它可以返回一个函数，这个函数可以计算一个给定参数的 $L2$ 正则化项的值。类似的，tf.contrib.layers.l1_regularizer 可以计算 $L1$ 正则化项的值。以下代码给出了使用这两个函数的样例：

```
weights = tf.constant([[1.0, -2.0], [-3.0, 4.0]])
with tf.Session() as sess:
    # 输出为 (|1|+|-2|+|-3|+|4|)×0.5=5。其中 0.5 为正则化项的权重。
    print sess.run(tf.contrib.layers.l1_regularizer(.5)(weights))
    # 输出为 (12+(-2)2+(-3)2+42)/2×0.5=7.5①。
    print sess.run(tf.contrib.layers.l2_regularizer(.5)(weights))
```

在简单的神经网络中，这样的方式就可以很好地计算带正则化的损失函数了。但当神经网络的参数增多之后，这样的方式首先可能导致损失函数 loss 的定义很长，可读性差且容易出错。但更主要的是，当网络结构复杂之后定义网络结构的部分和计算损失函数的部分可能不在同一个函数中，这样通过变量这种方式计算损失函数就不方便了。为了解决这个问题，可以使用 TensorFlow 中提供的集合（collection）。集合的概念在 3.1 节中介绍过，它可以在一个计算图（tf.Graph）中保存一组实体（比如张量）。以下代码给出了通过集合计算一个 5 层神经网络带 $L2$ 正则化的损失函数的计算方法。

```
import tensorflow as tf

# 获取一层神经网络边上的权重，并将这个权重的 L2 正则化损失加入名称为 'losses' 的集合中
def get_weight(shape, lambda):
    # 生成一个变量。
    var = tf.Variable(tf.random_normal(shape), dtype = tf.float32)
```

① TensorFlow 会将 $L2$ 的正则化损失值除以 2 使得求导得到的结果更加简洁。

```

# add_to_collection函数将这个新生成变量的 L2 正则化损失项加入集合。
# 这个函数的第一个参数'losses'是集合的名字，第二个参数是要加入这个集合的内容。
tf.add_to_collection(
    'losses', tf.contrib.layers.l2_regularizer(lambda)(var))
# 返回生成的变量。
return var

x = tf.placeholder(tf.float32, shape=(None, 2))
y_ = tf.placeholder(tf.float32, shape=(None, 1))
batch_size = 8
# 定义了每一层网络中节点的个数。
layer_dimension = [2, 10, 10, 10, 1]
# 神经网络的层数。
n_layers = len(layer_dimension)

# 这个变量维护前向传播时最深层的节点，开始的时候就是输入层。
cur_layer = x
# 当前层的节点个数。
in_dimension = layer_dimension[0]

# 通过一个循环来生成 5 层全连接的神经网络结构。
for i in range(1, n_layers):
    # layer_dimension[i]为下一层的节点个数。
    out_dimension = layer_dimension[i]
    # 生成当前层中权重的变量，并将这个变量的 L2 正则化损失加入计算图上的集合。
    weight = get_weight([in_dimension, out_dimension], 0.001)
    bias = tf.Variable(tf.constant(0.1, shape=[out_dimension]))
    # 使用 ReLU 激活函数。
    cur_layer = tf.nn.relu(tf.matmul(cur_layer, weight) + bias)
    # 进入下一层之前将下一层的节点个数更新为当前层节点个数。
    in_dimension = layer_dimension[i]

# 在定义神经网络前向传播的同时已经将所有的 L2 正则化损失加入了图上的集合，
# 这里只需要计算刻画模型在训练数据上表现的损失函数。
mse_loss = tf.reduce_mean(tf.square(y_ - cur_layer))

# 将均方差损失函数加入损失集合。
tf.add_to_collection('losses', mse_loss)

# get_collection 返回一个列表，这个列表是所有这个集合中的元素。在这个样例中，
# 这些元素就是损失函数的不同部分，将它们加起来就可以得到最终的损失函数。
loss = tf.add_n(tf.get_collection('losses'))

```

从上面的代码可以看出通过使用集合的方法在网络结构比较复杂的情况下可以使代码

的可读性更高。上面的代码给出的是一个只有 5 层的全连接网络，在更加复杂的网络结构中，使用这样的方式来计算损失函数将大大增强代码的可读性。

4.4.3 滑动平均模型

这一个小节将介绍另外一个可以使模型在测试数据上更健壮 (robust) 的方法——滑动平均模型。在采用随机梯度下降算法训练神经网络时，使用滑动平均模型在很多应用中都可以在一定程度提高最终模型在测试数据上的表现。

在 TensorFlow 中提供了 `tf.train.ExponentialMovingAverage` 来实现滑动平均模型。在初始化 `ExponentialMovingAverage` 时，需要提供一个衰减率 (decay)。这个衰减率将用于控制模型更新的速度。`ExponentialMovingAverage` 对每一个变量会维护一个影子变量 (shadow variable)，这个影子变量的初始值就是相应变量的初始值，而每次运行变量更新时，影子变量的值会更新为：

$$\text{shadow_variable} = \text{decay} \times \text{shadow_variable} + (1 - \text{decay}) \times \text{variable}$$

其中 `shadow_variable` 为影子变量，`variable` 为待更新的变量，`decay` 为衰减率。从公式中可以看到，`decay` 决定了模型更新的速度，`decay` 越大模型越趋于稳定。在实际应用中，`decay` 一般会设成非常接近 1 的数 (比如 0.999 或 0.9999)。为了使得模型在训练前期可以更新得更快，`ExponentialMovingAverage` 还提供了 `num_updates` 参数来动态设置 `decay` 的大小。如果在 `ExponentialMovingAverage` 初始化时提供了 `num_updates` 参数，那么每次使用的衰减率将是：

$$\min \left\{ \text{decay}, \frac{1 + \text{num_updates}}{10 + \text{num_updates}} \right\}$$

下面通过一段代码来解释 `ExponentialMovingAverage` 是如何被使用的。

```
import tensorflow as tf

# 定义一个变量用于计算滑动平均，这个变量的初始值为 0。注意这里手动指定了变量的
# 类型为 tf.float32，因为所有需要计算滑动平均的变量必须是实数型。
v1 = tf.Variable(0, dtype=tf.float32)
# 这里 step 变量模拟神经网络中迭代的轮数，可以用于动态控制衰减率。
step = tf.Variable(0, trainable=False)

# 定义一个滑动平均的类 (class)。初始化时给定了衰减率 (0.99) 和控制衰减率的变量 step。
ema = tf.train.ExponentialMovingAverage(0.99, step)
# 定义一个更新变量滑动平均的操作。这里需要给定一个列表，每次执行这个操作时
# 这个列表中的变量都会被更新。
maintain_averages_op = ema.apply([v1])
```

```

with tf.Session() as sess:
    # 初始化所有变量。
    init_op = tf.initialize_all_variables()
    sess.run(init_op)

    # 通过 ema.average(v1) 获取滑动平均之后变量的取值。在初始化之后变量 v1 的值和 v1 的
    # 滑动平均都为 0。
    print sess.run([v1, ema.average(v1)])          # 输出[0.0, 0.0]

    # 更新变量 v1 的值为 5。
    sess.run(tf.assign(v1, 5))
    # 更新 v1 的滑动平均值。衰减率为  $\min\{0.99, (1+\text{step})/(10+\text{step})\} = 0.1$ ，
    # 所以 v1 的滑动平均会被更新为  $0.1 \times 0 + 0.9 \times 5 = 4.5$ 。
    sess.run(maintain_averages_op)
    print sess.run([v1, ema.average(v1)])          # 输出[5.0, 4.5]

    # 更新 step 的值为 10000。
    sess.run(tf.assign(step, 10000))
    # 更新 v1 的值为 10。
    sess.run(tf.assign(v1, 10))
    # 更新 v1 的滑动平均值。衰减率为  $\min\{0.99, (1+\text{step})/(10+\text{step})\} \approx 0.999$ ，
    # 所以 v1 的滑动平均会被更新为  $0.99 \times 4.5 + 0.01 \times 10 = 4.555$ 。
    sess.run(maintain_averages_op)
    print sess.run([v1, ema.average(v1)])          # 输出[10.0, 4.5549998]

    # 再次更新滑动平均值，得到的新滑动平均值为  $0.99 \times 4.555 + 0.01 \times 10 = 4.60945$ 。
    sess.run(maintain_averages_op)
    print sess.run([v1, ema.average(v1)])          # 输出[10.0, 4.6094499]

```

上面的代码给出了 ExponentialMovingAverage 的简单样例，在第 5 章中将给出在真实应用中使用滑动平均的样例。

小结

本章详细讲解了使用神经网络实际问题过程中的各个环节。首先 4.1 节介绍了设计神经网络结构时的两个总体原则——非线性结构和多层结构。这一节先说明了深度学习基本上就是深层神经网络的代名词。然后通过对深度学习定义中两个性质的详细讲解，指

出了非线性结构和多层结构是解决复杂问题的必要方法。这一节通过具体的例子讲解了线性模型和浅层模型的局限性。

然后 4.2 节介绍了如何设计损失函数。神经网络是一个优化问题，而损失函数就刻画了神经网络需要优化的目标。这一节讲解了分类问题和回归问题中比较常用的损失函数，同时也介绍了如何设计更加贴近实际问题需求的损失函数。在这一节中通过一个实际样例讲解了不同损失函数对神经网络参数优化结果的影响。

接着 4.3 节介绍了优化神经网络时最常用的梯度下降算法和反向传播算法。在这一节中，主要讲解了梯度下降算法的基本概念和主体思想，并给出了通过梯度下降算法优化一个简单函数 $J(x)=x^2$ 的样例。通过这个例子，读者可以对神经网络的优化过程有一个大概的、直观的了解。这一节还介绍了随机梯度下降和使用 batch 的随机梯度下降算法，并给出了使用 TensorFlow 优化神经网络的计算框架。

最后 4.4 节介绍了三个神经网络优化过程中可能会遇到的问题，并介绍了解决这些问题的常用方法。首先 4.4.1 小节介绍了通过指数衰减的方式来设置学习率。通过这种方法，既可以加快训练初期的训练速度，同时在训练后期又不会出现损失函数在极小值周围徘徊往返的情况。然后 4.4.2 小节介绍了通过正则化解决过度拟合的问题。当损失函数仅取决于在训练数据上的拟合程度时，神经网络模型有可能只是“记忆”了所有的训练数据，而无法很好地对未知数据做出判断。正则化通过在损失函数中加入对模型复杂程度的因素，可以有效避免过拟合问题。最后 4.4.3 小节介绍了使用滑动平均模型让最后得到的模型在未知数据上更加健壮。

这一章讲解了使用神经网络模型时需要考虑的主要问题。从神经网络模型结构的设计、损失函数的设计、神经网络的优化和神经网络进一步调优四个方面覆盖了设计和优化神经网络过程中可能遇到的主要问题。在下面的第 5 章中，将通过一个具体的问题来验证本章中提到的神经网络优化方法。同时也将给出通过 TensorFlow 实现神经网络的最佳实践样例程序。

第 5 章 MNIST 数字识别问题

第 4 章介绍了训练神经网络模型时需要考虑的主要问题以及解决这些问题的常用方法。这一章将通过一个实际问题来验证第 4 章中介绍的解决方法。本章将使用的数据集是 MNIST 手写体数字识别数据集。在很多深度学习教程中，这个数据集都会被当作第一个案例。在验证神经网络优化方法的同时，本章也会介绍使用 TensorFlow 训练神经网络的最佳实践。

首先在 5.1 节中将介绍 MNIST 手写体数字识别数据集，并且给出 TensorFlow 程序处理 MNIST 数据^①。然后 5.2 节将对第 4 章中提到的神经网络结构设计和参数优化的不同方法，从实际的问题中验证不同优化方法带来的性能提升。接着在 5.3 和 5.4 两节中将指出 5.2 节中 TensorFlow 程序实现神经网络的不足之处，并介绍 TensorFlow 的最佳实践来解决这些不足。其中，5.3 节将介绍 TensorFlow 变量重用的问题和变量的命名空间；5.4 节将介绍如何将一个神经网络模型持久化，使得之后可以直接使用训练好的模型。最后在 5.5 节中将整合 5.3 和 5.4 节中介绍的 TensorFlow 最佳实践，通过一个完整的 TensorFlow 程序解决 MNIST 问题。

5.1 MNIST 数据处理

MNIST 是一个非常有名的手写体数字识别数据集，在很多资料中，这个数据集都会被用作深度学习的入门样例。本节中将大致讲解这个数据集的基本情况，并介绍 TensorFlow 对 MNIST 数据集做的封装。TensorFlow 的封装让使用 MNIST 数据集变得更加方便。MNIST 数据集是 NIST 数据集的一个子集，它包含了 60000 张图片作为训练数据，10000 张图片作

^① TensorFlow 提供了封装好的 MNIST 数据集处理类，在这里将直接使用这个类。关于如何处理图像数据将在第 7 章中详细介绍。

为测试数据。在 MNIST 数据集中的每一张图片都代表了 0~9 中的一个数字。图片的大小都为 28×28，且数字都会出现在图片的正中间。图 5-1 展示了一张数字图片及和它对应的像素矩阵。




图 5-1 数字图片及其像素矩阵

在图 5-1 的左侧显示了一张数字 1 的图片，而右侧显示了这个图片所对应的像素矩阵^①。在 Yann LeCun 教授的网站中 (<http://yann.lecun.com/exdb/mnist>) 对 MNIST 数据集做出了详细的介绍。MNIST 数据集提供了 4 个下载文件，表 5-1 归纳了下载文件中提供的内容。

表 5-1 MNIST 数据下载地址和内容

网址	内容
http://yann.lecun.com/exdb/mnist/train-images-idx3-ubyte.gz	训练数据图片
http://yann.lecun.com/exdb/mnist/train-labels-idx1-ubyte.gz	训练数据答案
http://yann.lecun.com/exdb/mnist/t10k-images-idx3-ubyte.gz	测试数据图片
http://yann.lecun.com/exdb/mnist/t10k-labels-idx1-ubyte.gz	测试数据答案

虽然这个数据集只提供了训练和测试数据，但是为了验证模型训练的效果，一般会从训练数据中划分出一部分数据作为验证 (validation) 数据。在 5.2.2 小节中将更加详细地介绍验证数据的作用。为了方便使用，TensorFlow 提供了一个类来处理 MNIST 数据。这个类会自动下载并转化 MNIST 数据的格式，将数据从原始的数据包中解析成训练和测试神经网络时使用的格式。下面给出了使用这个函数的样例程序。

^① MNIST 数据集中图片的像素矩阵大小为 28×28，但为了更清楚地展示，图 5-1 右侧显示的为 14×14 矩阵。

```

from tensorflow.examples.tutorials.mnist import input_data

# 载入 MNIST 数据集, 如果指定地址/path/to/MNIST_data 下没有已经下载好的数据,
# 那么 TensorFlow 会自动从表 5-1 给出的网址下载数据。
mnist = input_data.read_data_sets("/path/to/MNIST_data/", one_hot=True)

# 打印 Training data size: 55000。
print "Training data size: ", mnist.train.num_examples

# 打印 Validating data size: 5000。
print "Validating data size: ", mnist.validation.num_examples

# 打印 Testing data size: 10000。
print "Testing data size: ", mnist.test.num_examples

# 打印 Example training data: [ 0. 0. 0. ... 0.380 0.376 ... 0. ]。
print "Example training data: ", mnist.train.images[0]

# 打印 Example training data label:
# [ 0. 0. 0. 0. 0. 0. 0. 1. 0. 0.]
print "Example training data label: ", mnist.train.labels[0]

```

从上面的代码中可以看出, 通过 `input_data.read_data_sets` 函数生成的类会自动将 MNIST 数据集划分为 `train`、`validation` 和 `test` 三个数据集, 其中 `train` 这个集合内有 55000 张图片, `validation` 集合内有 5000 张图片, 这两个集合组成了 MNIST 本身提供的训练数据集。`test` 集合内有 10000 张图片, 这些图片都来自于 MNIST 提供的测试数据集。处理后的每一张图片是一个长度为 784 的一维数组, 这个数组中的元素对应了图片像素矩阵中的每一个数字 ($28 \times 28 = 784$)。因为神经网络的输入是一个特征向量, 所以在此把一张二维图像的像素矩阵放到一个一维数组中可以方便 TensorFlow 将图片的像素矩阵提供给神经网络的输入层。像素矩阵中元素的取值范围为 $[0, 1]$, 它代表了颜色的深浅。其中 0 表示白色背景 (background), 1 表示黑色前景 (foreground)。为了方便使用随机梯度下降, `input_data.read_data_sets` 函数生成的类还提供了 `mnist.train.next_batch` 函数, 它可以从所有的训练数据中读取一小部分作为一个训练 batch。以下代码显示了如何使用这个功能。

```

batch_size = 100
xs, ys = mnist.train.next_batch(batch_size)
# 从 train 的集合中选取 batch_size 个训练数据。
print "X shape:", xs.shape
# 输出 X shape: (100, 784)。
print "Y shape:", ys.shape
# 输出 Y shape: (100, 10)。

```

5.2 神经网络模型训练及不同模型结果对比

本节将利用 MNIST 数据集实现并研究第 4 章中介绍的神经网络模型设计及优化的方法。首先, 在 5.2.1 小节中将给出一个完整的 TensorFlow 程序来解决 MNIST 问题。这个程序整合了第 4 章中介绍的所有优化方法, 训练好的神经网络模型在 MNIST 测试数据集上可以达到 98.4% 左右的正确率。然后 5.2.2 小节将介绍验证数据集在训练神经网络过程中的作用。这一小节将通过 5.2.1 小节中得到的实验数据来证明, 神经网络在验证数据集上的表现可以近似地作为评价不同神经网络模型的标准或者决定迭代轮数的依据。最后 5.2.3 小节将通过 MNIST 数据集验证第 4 章中介绍的每一个优化方法。通过在 MNIST 数据集上的实验可以看到, 这些优化方法都可以或多或少地提高神经网络的分类正确率。

5.2.1 TensorFlow 训练神经网络

这一小节将给出一个完整的 TensorFlow 程序来解决 MNIST 手写体数字识别问题。这一小节中给出的程序实现了第 4 章中介绍的神经网络结构设计和训练优化的所有方法。在给出具体的代码之前, 先回顾一下第 4 章中提到的主要概念。在神经网络的结构上, 深度学习一方面需要使用激活函数实现神经网络模型的去线性化, 另一方面需要使用一个或多个隐藏层使得神经网络的结构更深, 以解决复杂问题。在训练神经网络时, 第 4 章介绍了使用带指数衰减的学习率设置、使用正则化来避免过度拟合, 以及使用滑动平均模型来使得最终模型更加健壮。以下代码给出了一个在 MNIST 数据集上实现这些功能的完整的 TensorFlow 程序。

```
import tensorflow as tf
from tensorflow.examples.tutorials.mnist import input_data

# MNIST 数据集相关的常数。
INPUT_NODE = 784          # 输入层的节点数。对于 MNIST 数据集, 这个就等于图片的像素。
OUTPUT_NODE = 10          # 输出层的节点数。这个等于类别的数目。因为在 MNIST 数据集中
                           # 需要区分的是 0~9 这 10 个数字, 所以这里输出层的节点数为 10。

# 配置神经网络的参数。
LAYER1_NODE = 500         # 隐藏层节点数。这里使用只有一个隐藏层的网络结构作为样例。
                           # 这个隐藏层有 500 个节点。
BATCH_SIZE = 100         # 一个训练 batch 中的训练数据个数。数字越小时, 训练过程越接近
                           # 随机梯度下降; 数字越大时, 训练越接近梯度下降。
LEARNING_RATE_BASE = 0.8  # 基础的学习率。
LEARNING_RATE_DECAY = 0.99 # 学习率的衰减率。
```

```

REGULARIZATION_RATE = 0.0001      # 描述模型复杂度的正则化项在损失函数中的系数。
TRAINING_STEPS = 30000             # 训练轮数。
MOVING_AVERAGE_DECAY = 0.99       # 滑动平均衰减率。

# 一个辅助函数，给定神经网络的输入和所有参数，计算神经网络的前向传播结果。在这里
# 定义了一个使用 ReLU 激活函数的三层全连接神经网络。通过加入隐藏层实现了多层网络结构，
# 通过 ReLU 激活函数实现了去线性化。在这个函数中也支持传入用于计算参数平均值的类，
# 这样方便在测试时使用滑动平均模型。
def inference(input_tensor, avg_class, weights1, biases1,
              weights2, biases2):
    # 当没有提供滑动平均类时，直接使用参数当前的取值。
    if avg_class == None:
        # 计算隐藏层的前向传播结果，这里使用了 ReLU 激活函数。
        layer1 = tf.nn.relu(tf.matmul(input_tensor, weights1) + biases1)

        # 计算输出层的前向传播结果。因为在计算损失函数时会一并计算 softmax 函数，
        # 所以这里不需要加入激活函数。而且不加入 softmax 不会影响预测结果。因为预测时
        # 使用的是不同类别对应节点输出值的相对大小，有没有 softmax 层对最后分类结果的
        # 计算没有影响。于是在计算整个神经网络的前向传播时可以不加入最后的 softmax 层。
        return tf.matmul(layer1, weights2) + biases2

    else:
        # 首先使用 avg_class.average 函数来计算得出变量的滑动平均值，
        # 然后再计算相应的神经网络前向传播结果。
        layer1 = tf.nn.relu(
            tf.matmul(input_tensor, avg_class.average(weights1)) +
            avg_class.average(biases1))
        return tf.matmul(layer1, avg_class.average(weights2)) +
            avg_class.average(biases2)

# 训练模型的过程。
def train(mnist):
    x = tf.placeholder(tf.float32, [None, INPUT_NODE], name='x-input')
    y_ = tf.placeholder(tf.float32, [None, OUTPUT_NODE], name='y-input')

    # 生成隐藏层的参数。
    weights1 = tf.Variable(
        tf.truncated_normal([INPUT_NODE, LAYER1_NODE], stddev=0.1))
    biases1 = tf.Variable(tf.constant(0.1, shape=[LAYER1_NODE]))
    # 生成输出层的参数。
    weights2 = tf.Variable(
        tf.truncated_normal([LAYER1_NODE, OUTPUT_NODE], stddev=0.1))
    biases2 = tf.Variable(tf.constant(0.1, shape=[OUTPUT_NODE]))

    # 计算在当前参数下神经网络前向传播的结果。这里给出的用于计算滑动平均的类为 None，

```

```

# 所以函数不会使用参数的滑动平均值。
y = inference(x, None, weights1, biases1, weights2, biases2)

# 定义存储训练轮数的变量。这个变量不需要计算滑动平均值，所以这里指定这个变量为
# 不可训练的变量 (trainable=False)。在使用 TensorFlow 训练神经网络时，
# 一般会将代表训练轮数的变量指定为不可训练的参数。
global_step = tf.Variable(0, trainable=False)

# 给定滑动平均衰减率和训练轮数的变量，初始化滑动平均类。在第 4 章中介绍过给
# 定训练轮数的变量可以加快训练早期变量的更新速度。
variable_averages = tf.train.ExponentialMovingAverage(
    MOVING_AVERAGE_DECAY, global_step)

# 在所有代表神经网络参数的变量上使用滑动平均。其他辅助变量（比如 global_step）就
# 不需要了。tf.trainable_variables 返回的就是图上集合
# GraphKeys.TRAINABLE_VARIABLES 中的元素。这个集合的元素就是所有没有指定
# trainable=False 的参数。
variables_averages_op = variable_averages.apply(
    tf.trainable_variables())

# 计算使用了滑动平均之后的前向传播结果。第 4 章中介绍过滑动平均不会改变变量本身的
# 取值，而是会维护一个影子变量来记录其滑动平均值。所以当需要使用这个滑动平均值时，
# 需要明确调用 average 函数。
average_y = inference(
    x, variable_averages, weights1, biases1, weights2, biases2)

# 计算交叉熵作为刻画预测值和真实值之间差距的损失函数。这里使用了 TensorFlow 中提
# 供的 sparse_softmax_cross_entropy_with_logits 函数来计算交叉熵。当分类
# 问题只有一个正确答案时，可以使用这个函数来加速交叉熵的计算。MNIST 问题的图片中
# 只包含了 0~9 中的一个数字，所以可以使用这个函数来计算交叉熵损失。这个函数的第一个
# 参数是神经网络不包括 softmax 层的前向传播结果，第二个是训练数据的正确答案。因为
# 标准答案是一个长度为 10 的一维数组，而该函数需要提供的是一个正确答案的数字，所以需
# 要使用 tf.argmax 函数来得到正确答案对应的类别编号。
cross_entropy = tf.nn.sparse_softmax_cross_entropy_with_logits(
    y, tf.argmax(y, 1))
# 计算在当前 batch 中所有样例的交叉熵平均值。
cross_entropy_mean = tf.reduce_mean(cross_entropy)

# 计算 L2 正则化损失函数。
regularizer = tf.contrib.layers.l2_regularizer(REGULARIZATION_RATE)
# 计算模型的正则化损失。一般只计算神经网络边上权重的正则化损失，而不使用偏置项。
regularization = regularizer(weights1) + regularizer(weights2)
# 总损失等于交叉熵损失和正则化损失的和。
loss = cross_entropy_mean + regularization
# 设置指数衰减的学习率。

```



```

learning_rate = tf.train.exponential_decay(
    LEARNING_RATE_BASE,      # 基础的学习率，随着迭代的进行，更新变量时使用的
                              # 学习率在这个基础上递减。
    global_step,              # 当前迭代的轮数。
    mnist.train.num_examples / BATCH_SIZE, # 过完所有的训练数据需要的迭
                                      # 代次数。
    LEARNING_RATE_DECAY)      # 学习率衰减速度。

# 使用 tf.train.GradientDescentOptimizer 优化算法来优化损失函数。注意这里损失函数
# 包含了交叉熵损失和 L2 正则化损失。
train_step = tf.train.GradientDescentOptimizer(learning_rate)\
    .minimize(loss, global_step=global_step)

# 在训练神经网络模型时，每过一遍数据既需要通过反向传播来更新神经网络中的参数，
# 又要更新每一个参数的滑动平均值。为了一次完成多个操作，TensorFlow 提供了
# tf.control_dependencies 和 tf.group 两种机制。下面两行程序和
# train_op = tf.group(train_step, variables_averages_op) 是等价的。
with tf.control_dependencies([train_step, variables_averages_op]):
    train_op = tf.no_op(name='train')

# 检验使用了滑动平均模型的神经网络前向传播结果是否正确。tf.argmax(average_y, 1)
# 计算每一个样例的预测答案。其中 average_y 是一个 batch_size * 10 的二维数组，每一行
# 表示一个样例的前向传播结果。tf.argmax 的第二个参数“1”表示选取最大值的操作仅在第一
# 个维度中进行，也就是说，只在每一行选取最大值对应的下标。于是得到的结果是一个长度为
# batch 的一维数组，这个一维数组中的值就表示了每一个样例对应的数字识别结果。tf.equal
# 判断两个张量的每一维是否相等，如果相等返回 True，否则返回 False。
correct_prediction = tf.equal(tf.argmax(average_y, 1), tf.argmax(y, 1))
# 这个运算首先将一个布尔型的数值转换为实数型，然后计算平均值。这个平均值就是模型在这
# 一组数据上的正确率。
accuracy = tf.reduce_mean(tf.cast(correct_prediction, tf.float32))

# 初始化会话并开始训练过程。
with tf.Session() as sess:
    tf.initialize_all_variables().run()
    # 准备验证数据。一般在神经网络的训练过程中会通过验证数据来大致判断停止的
    # 条件和评判训练的效果。
    validate_feed = {x: mnist.validation.images,
                     y: mnist.validation.labels}

    # 准备测试数据。在真实的应用中，这部分数据在训练时是不可见的，这个数据只是作为模
    # 型优劣的最后评价标准。
    test_feed = {x: mnist.test.images, y: mnist.test.labels}

    # 迭代地训练神经网络。
    for i in range(TRAINING_STEPS):

```



```

# 每 1000 轮输出一次在验证数据集上的测试结果。
if i % 1000 == 0:
# 计算滑动平均模型在验证数据上的结果。因为 MNIST 数据集比较小，所以一次
# 可以处理所有的验证数据。为了计算方便，本样例程序没有将验证数据划分为更
# 小的 batch。当神经网络模型比较复杂或者验证数据比较大时，太大的 batch
# 会导致计算时间过长甚至发生内存溢出的错误。
    validate_acc = sess.run(accuracy, feed_dict=validate_feed)
    print("After %d training step(s), validation accuracy "
          "using average model is %g " % (i, validate_acc))

# 产生这一轮使用的一个 batch 的训练数据，并运行训练过程。
xs, ys = mnist.train.next_batch(BATCH_SIZE)
sess.run(train_op, feed_dict={x: xs, y: ys})

# 在训练结束之后，在测试数据上检测神经网络模型的最终正确率。
test_acc = sess.run(accuracy, feed_dict=test_feed)
print("After %d training step(s), test accuracy using average "
      "model is %g" % (TRAINING_STEPS, test_acc))

# 主程序入口。
def main(argv=None):
    # 声明处理 MNIST 数据集的类，这个类在初始化时会自动下载数据。
    mnist = input_data.read_data_sets("/tmp/data", one_hot=True)
    train(mnist)

# TensorFlow 提供的一个主程序入口，tf.app.run 会调用上面定义的 main 函数。
if __name__ == '__main__':
    tf.app.run()

```

运行上面的程序，将得到类似下面的输出结果^①：

```

Extracting /tmp/data/train-images-idx3-ubyte.gz
Extracting /tmp/data/train-labels-idx1-ubyte.gz
Extracting /tmp/data/t10k-images-idx3-ubyte.gz
Extracting /tmp/data/t10k-labels-idx1-ubyte.gz
After 0 training step(s), validation accuracy on average model is 0.105
After 1000 training step(s), validation accuracy using average model is 0.9774
After 2000 training step(s), validation accuracy using average model is 0.9816
After 3000 training step(s), validation accuracy using average model is 0.9834
After 4000 training step(s), validation accuracy using average model is 0.9832
...
After 27000 training step(s), validation accuracy using average model is 0.984

```

① 因为神经网络模型训练过程中的随机因素，读者不会得到一模一样的结果。

```

After 28000 training step(s), validation accuracy using average model is 0.985
After 29000 training step(s), validation accuracy using average model is 0.985
After 29999 training step(s), validation accuracy using average model is 0.985
After 30000 training step(s), test accuracy on average model is 0.984

```

从上面的结果可以看出，在训练初期，随着训练的进行，模型在验证数据集上的表现越来越好。从第 4000 轮开始，模型在验证数据集上的表现开始波动，这说明模型已经接近极小值了，所以迭代也就可以结束了。下面的 5.2.2 小节将详细介绍验证数据集的作用。

5.2.2 使用验证数据集判断模型效果

在 5.2.1 小节给出了使用神经网络解决 MNIST 问题的完整程序。在这个程序的开始设置了初始学习率、学习率衰减率、隐藏层节点数量、迭代轮数等 7 种不同的参数。那么如何设置这些参数的取值呢？在大部分情况下，配置神经网络的这些参数都是需要通过实验来调整的。虽然一个神经网络模型的效果最终是通过测试数据来评判的，但是我们不能直接通过模型在测试数据上的效果来选择参数。使用测试数据来选取参数可能会导致神经网络模型过度拟合测试数据，从而失去对未知数据的预判能力。因为一个神经网络模型的最终目标是对未知数据提供判断，所以为了估计模型在未知数据上的效果，需要保证测试数据在训练过程中是不可见的。只有这样才能保证通过测试数据评估出来的效果和在实际应用场景下模型对未知数据预判的效果是接近的。于是，为了评测神经网络模型在不同参数下的效果，一般会从训练数据中抽取一部分作为验证数据。使用验证数据就可以评判不同参数取值下模型的表现。除了使用验证数据集，还可以采用交叉验证（cross validation）的方式来验证模型效果。但因为神经网络训练时间本身就比较长，采用 cross validation 会花费大量时间。所以在海量数据的情况下，一般会更多地采用验证数据集的形式来评测模型的效果。

在本小节中，为了说明验证数据在一定程度上可以作为模型效果的评判标准，我们将对比在不同迭代轮数的情况下，模型在验证数据和测试数据上的正确率。为了同时得到同一个模型在验证数据和测试数据上的正确率，可以在每 1000 轮的输出中加入在测试数据集上的正确率。在 5.2.1 小节给出的代码中加入以下代码，就可以得到每 1000 轮迭代后，使用了滑动平均的模型在验证数据和测试数据上的正确率。

```

# 计算滑动平均模型在测试数据和验证数据上的正确率。
validate_acc = sess.run(accuracy, feed_dict=validate_feed)
test_acc = sess.run(accuracy, feed_dict=test_feed)
# 输出正确率信息。
print("After %d training step(s), validation accuracy using average "
      "model is %g, test accuracy using average model is %g" %
      (i, validate_acc, test_acc))

```

图 5-2 给出了通过上面代码得到的每 1000 轮滑动平均模型在不同数据集上的正确率曲线。图 5-2 中灰色的曲线表示随着迭代轮数的增加，模型在验证数据上的正确率；而黑色的曲线表示了测试数据上的正确率。从图 5-2 中可以看出，虽然这两条曲线不会完全重合，但是这两条曲线的趋势基本一样，而且他们的相关系数（correlation coefficient）大于 0.9999。这意味着在 MNIST 问题上，完全可以通过模型在验证数据上的表现来判断一个模型的优劣。




图 5-2 不同迭代轮数下滑动平均模型在验证数据集和测试数据集上的正确率

当然，以上结论是针对 MNIST 这个数据集的，对于其他问题，还需要具体问题具体分析。不同问题的数据分布不一样，如果验证数据分布不能很好地代表测试数据分布，那么模型在这两个数据集上的表现就有可能不一样。所以，验证数据的选取方法是非常重要的，一般来说选取的验证数据分布越接近测试数据分布，模型在验证数据上的表现越可以体现模型在测试数据上的表现。但通过本小节中介绍的实验，至少可以说明通过神经网络在验证数据上的效果来选取模型的参数是一个可行的方案。

5.2.3 不同模型效果比较

本小节将通过 MNIST 数据集来比较第 4 章中提到的不同优化方法对神经网络模型正确率的影响。本小节将使用神经网络模型在 MNIST 测试数据集上的正确率作为评价不同优化方法的标准。在本小节中一个模型在 MNIST 测试数据集上的正确率将简称为“正确率”。在第 4 章中提到了设计神经网络时的 5 种优化方法。在神经网络结构的设计上，需要使用激活函数和多层隐藏层。在神经网络优化时，可以使用指数衰减的学习率、加入正则化的

损失函数以及滑动平均模型。在图 5-3 中，给出了在相同神经网络参数下^①，使用不同优化方法，经过 30000 轮训练迭代后，得到的最终模型的正确率^②。图 5-3 给出的结果中包含了使用所有优化方法训练得到的模型和不用其中某一项优化方法训练得到的模型。通过这种方式，可以有效验证每一项优化方法的效果。




图 5-3 不同模型的正确率

从图 5-3 中可以很明显地看出，调整神经网络的结构对最终的正确率有非常大的影响。没有隐藏层或者没有激活函数时，模型的正确率只有大约 92.6%，这个数字要远远小于使用了隐藏层和激活函数时可以达到的大约 98.4% 的正确率。这说明神经网络的结构对最终模型的效果有本质性的影响。第 6 章将会介绍一种更加特殊的神经网络结构——卷积神经网络。卷积神经网络可以更加有效地处理图像信息。通过卷积神经网络，可以进一步将正确率提高到大约 99.5%。

从图 5-3 上的数字中可发现使用滑动平均模型、指数衰减的学习率和使用正则化带来的正确率的提升并不是特别明显。其中使用了所有优化算法的模型和不使用滑动平均的模型以及不使用指数衰减的学习率的模型都可以达到大约 98.4% 的正确率。这是因为滑动平均模型和指数衰减的学习率在某种程度上都是限制神经网络中参数更新的速度，然而在 MNIST 数据上，因为模型收敛的速度很快，所以这两种优化对最终模型的影响不大。从图 5-2 中可以看到，当模型迭代到 4000 轮时正确率就已经接近最终的正确率了。而在迭代

① 在本小节中，不同神经网络模型使用的参数和 5.2.1 小节给出的代码中的参数一致。唯一的例外是不使用激活函数的模型使用的学习率为 0.05。

② 因为神经网络的训练过程存在随机因素，本小节中列出的所有结果都是 10 次运行的平均值。

的早期, 是否使用滑动平均模型或者指数衰减的学习率对训练结果的影响相对较小。图 5-4 显示了不同迭代轮数时, 使用了所有优化方法的模型的正确率与平均绝对梯度^①的变化趋势。图 5-5 显示了不同迭代轮数时, 正确率与衰减之后的学习率的变化趋势。




图 5-4 使用了所有优化方法的模型正确率与平均绝对梯度在不同迭代轮数时的变化趋势




图 5-5 使用了所有优化方法的模型的正确率与学习率在不同迭代轮数时的变化趋势

从图 5-4 中可以看到, 前 4000 轮迭代对模型的改变是最大的。在 4000 轮之后, 因为梯度本身比较小, 所以参数的改变也就比较缓慢了。于是滑动平均模型或者指数衰减的学

① 平均绝对梯度是所有参数梯度绝对值的平均数。

习率的作用也就没有那么突出了。从图 5-5 中可以看到, 学习率曲线呈现出阶梯状衰减, 在前 4000 轮时, 衰减之后的学习率和最初的学习率差距并不大。那么, 这是否能说明这些优化方法作用不大呢? 答案是否定的。当问题更加复杂时, 迭代不会这么快接近收敛, 这时滑动平均模型和指数衰减的学习率可以发挥更大的作用。比如在 Cifar-10 图像分类数据集上, 使用滑动平均模型可以将错误率降低 11%, 而使用指数衰减的学习率可以将错误率降低 7%。

相比滑动平均模型和指数衰减学习率, 使用加入正则化的损失函数给模型效果带来的提升要相对显著。使用了正则化损失函数的神经网络模型可以降低大约 6% 的错误率 (从 1.69% 降低到 1.59%)。图 5-6 和图 5-7 显示了正则化给模型优化过程带来的影响。图 5-6 和图 5-7 对比了两个使用了不同损失函数的神经网络模型。一个模型只最小化交叉熵损失, 以下代码给出了只优化交叉熵模型的模型优化函数的声明语句。

```
train_step = tf.train.GradientDescentOptimizer(learning_rate)\
    .minimize(cross_entropy_mean, global_step=global_step)
```

另一个模型优化的是交叉熵和 $L2$ 正则化损失的和。以下代码给出了这个模型优化函数的声明语句。

```
loss = cross_entropy_mean + regularaztion
train_step = tf.train.GradientDescentOptimizer(learning_rate)\
    .minimize(loss, global_step=global_step)
```

在图 5-6 中灰色和黑色的实线给出了两个模型正确率的变化趋势, 虚线给出了在当前训练 batch 上的交叉熵损失。




图 5-6 不同模型在不同迭代轮数时交叉熵和正确率的关系

从图 5-6 中可以看出, 只优化交叉熵的模型在训练数据上的交叉熵损失 (灰色虚线)

要比优化总损失的模型更小（黑色虚线）。然而在测试数据上，优化总损失的模型（黑色实线）却要好于只优化交叉熵的模型（灰色实线）。这个原因就是第 4 章中介绍的过拟合问题。只优化交叉熵的模型可以更好地拟合训练数据（交叉熵损失更小），但是却不能很好地挖掘数据中潜在的规律来判断未知的测试数据，所以在测试数据上的正确率低。

图 5-7 显示了不同模型的损失函数的变化趋势。图 5-7 的左侧显示了只优化交叉熵的模型损失函数的变化规律。可以看到随着迭代的进行，正则化损失是在不断加大的。因为 MNIST 问题相对比价简单，迭代后期的梯度很小（参考图 5-4），所以正则化损失的增长也不快。如果问题更加复杂，迭代后期的梯度更大，就会发现总损失（交叉熵损失加上正则化损失）会呈现出一个 U 字型。在图 5-7 的右侧，显示了优化总损失的模型损失函数的变化规律。从图 5-7 中可以看出，这个模型的正则化损失部分也可以随着迭代的进行越来越小，从而使得整体的损失呈现一个逐步递减的趋势。




图 5-7 正则化损失值和总损失的变化趋势

总的来说，通过 MNIST 数据集有效地验证了激活函数、隐藏层可以给模型的效果带来质的飞跃。由于 MNIST 问题本身相对简单，滑动平均模型、指数衰减的学习率和正则化损失对最终正确率的提升效果不明显。但通过进一步分析实验的结果，可以得出这些优化方法确实可以解决第 4 章中提到的神经网络优化过程中的问题。当需要解决的问题和使用到的神经网络模型更加复杂时，这些优化方法将更有可能对训练效果产生更大的影响。

5.3 变量管理

在 5.2.1 小节中将计算神经网络前向传播结果的过程抽象成了一个函数。通过这种方式在训练和测试的过程中可以统一调用同一个函数来得模型的前向传播结果。在 5.2.1 小节中，这个函数的定义为：

```
def inference(input_tensor, avg_class, weights1, biases1, weights2, biases2):
```

从定义中可以看到，这个函数的参数中包括了神经网络中的所有参数。然而，当神经网络的结构更加复杂、参数更多时，就需要一个更好的方式来传递和管理神经网络中的参数了。TensorFlow 提供了通过变量名称来创建或者获取一个变量的机制。通过这个机制，在不同的函数中可以直接通过变量的名字来使用变量，而不需要将变量通过参数的形式到处传递。TensorFlow 中通过变量名称获取变量的机制主要是通过 `tf.get_variable` 和 `tf.variable_scope` 函数实现的。下面将分别介绍如何使用这两个函数。

第4章介绍了通过 `tf.Variable` 函数来创建一个变量。除了 `tf.Variable` 函数，TensorFlow 还提供了 `tf.get_variable` 函数来创建或者获取变量。当 `tf.get_variable` 用于创建变量时，它和 `tf.Variable` 的功能是基本等价的。以下代码给出了通过这两个函数创建同一个变量的样例。

```
# 下面这两个定义是等价的。
v = tf.get_variable("v", shape=[1],
                    initializer=tf.constant_initializer(1.0))
v = tf.Variable(tf.constant(1.0, shape=[1]), name="v")
```

从上面的代码中可以看出，通过 `tf.Variable` 和 `tf.get_variable` 函数创建变量的过程基本上是一样的。`tf.get_variable` 函数调用时提供的维度(shape)信息以及初始化方法(initializer)的参数和 `tf.Variable` 函数调用时提供的初始化过程中的参数也类似。TensorFlow 中提供的 `initializer` 函数和 3.4.3 小节中介绍的随机数以及常量生成函数大部分是一一对应的。比如，在上面的样例程序中使用到的常数初始化函数 `tf.constant_initializer` 和常数生成函数 `tf.constant` 功能上就是一致的。TensorFlow 提供了 7 种不同的初始化函数，表 5-2 总结了它们的功能和主要参数。

表 5-2 TensorFlow 中的变量初始化函数

初始化函数	功能	主要参数
<code>tf.constant_initializer</code>	将变量初始化为给定常量	常量的取值
<code>tf.random_normal_initializer</code>	将变量初始化为满足正态分布的随机值	正态分布的均值和标准差
<code>tf.truncated_normal_initializer</code>	将变量初始化为满足正态分布的随机值，但如果随机出来的值偏离平均值超过 2 个标准差，那么这个数将会被重新随机	正态分布的均值和标准差
<code>tf.random_uniform_initializer</code>	将变量初始化为满足平均分布的随机值	最大、最小值
<code>tf.uniform_unit_scaling_initializer</code>	将变量初始化为满足平均分布但不影响输出数量级的随机值	factor(产生随机值时乘以的系数)
<code>tf.zeros_initializer</code>	将变量设置为全 0	变量维度
<code>tf.ones_initializer</code>	将变量设置为全 1	变量维度

`tf.get_variable` 函数与 `tf.Variable` 函数最大的区别在于指定变量名称的参数。对于 `tf.Variable` 函数，变量名称是一个可选的参数，通过 `name="v"` 的形式给出。但是对于

`tf.get_variable` 函数，变量名称是一个必填的参数。`tf.get_variable` 会根据这个名字去创建或者获取变量。在上面的样例程序中，`tf.get_variable` 首先会试图去创建一个名字为 `v` 的参数，如果创建失败（比如已经有同名的参数），那么这个程序就会报错。这是为了避免无意识的变量复用造成的错误。比如在定义神经网络参数时，第一层网络的权重已经叫 `weights` 了，那么在创建第二层神经网络时，如果参数名仍然叫 `weights`，就会触发变量重用的错误。否则两层神经网络共用一个权重会出现一些比较难以发现的错误。如果需要通过 `tf.get_variable` 获取一个已经创建的变量，需要通过 `tf.variable_scope` 函数来生成一个上下文管理器，并明确指定在这个上下文管理器中，`tf.get_variable` 将直接获取已经生成的变量。下面给出了一段代码说明如何通过 `tf.variable_scope` 函数来控制 `tf.get_variable` 函数获取已经创建过的变量。

```
# 在名字为 foo 的命名空间内创建名字为 v 的变量。
with tf.variable_scope("foo"):
    v = tf.get_variable(
        "v", [1], initializer=tf.constant_initializer(1.0))

# 因为在命名空间 foo 中已经存在名字为 v 的变量，所有下面的代码将会报错：
# Variable foo/v already exists, disallowed. Did you mean to set reuse=True
# in VarScope?
with tf.variable_scope("foo"):
    v = tf.get_variable("v", [1])

# 在生成上下文管理器时，将参数 reuse 设置为 True。这样 tf.get_variable 函数将直接获取
# 已经声明的变量。
with tf.variable_scope("foo", reuse=True):
    v1 = tf.get_variable("v", [1])
    print v == v1    # 输出为 True，代表 v，v1 代表的是相同的 TensorFlow 中变量。

# 将参数 reuse 设置为 True 时，tf.variable_scope 将只能获取已经创建过的变量。因为在
# 命名空间 bar 中还没有创建变量 v，所以下面的代码将会报错：
# Variable bar/v does not exist, disallowed. Did you mean to set reuse=None
# in VarScope?
with tf.variable_scope("bar", reuse=True):
    v = tf.get_variable("v", [1])
```

上面的样例简单地说明了通过 `tf.variable_scope` 函数可以控制 `tf.get_variable` 函数的语义。当 `tf.variable_scope` 函数使用参数 `reuse=True` 生成上下文管理器时，这个上下文管理器内所有的 `tf.get_variable` 函数会直接获取已经创建的变量。如果变量不存在，则 `tf.get_variable` 函数将报错；相反，如果 `tf.variable_scope` 函数使用参数 `reuse=None` 或者 `reuse=False` 创建上下文管理器，`tf.get_variable` 操作将创建新的变量。如果同名的变量已经存在，则

`tf.get_variable` 函数将报错。TensorFlow 中 `tf.variable_scope` 函数是可以嵌套的。下面的程序说明了当 `tf.variable_scope` 函数嵌套时，`reuse` 参数的取值是如何确定的。

```
with tf.variable_scope("root"):
    # 可以通过tf.get_variable_scope().reuse函数来获取当前上下文管理器中reuse参
    # 数的取值。
    print tf.get_variable_scope().reuse    # 输出False,即最外层reuse是False.

    with tf.variable_scope("foo", reuse=True): # 新建一个嵌套的上下文管理器,
                                                # 并指定reuse为True。
        print tf.get_variable_scope().reuse    # 输出True。
        with tf.variable_scope("bar"):          # 新建一个嵌套的上下文管理器但
                                                # 不指定reuse,这时reuse
                                                # 的取值会和外面一层保持一致。
            print tf.get_variable_scope().reuse # 输出True。
        print tf.get_variable_scope().reuse    # 输出False。退出reuse设置
                                                # 为True的上下文之后
                                                # reuse的值又回到了False。
```

`tf.variable_scope` 函数生成的上下文管理器也会创建一个 TensorFlow 中的命名空间，在命名空间内创建的变量名称都会带上这个命名空间名作为前缀。所以，`tf.variable_scope` 函数除了可以控制 `tf.get_variable` 执行的功能之外，这个函数也提供了一个管理变量命名空间的方式。以下代码显示了如何通过 `tf.variable_scope` 来管理变量的名称。

```
v1 = tf.get_variable("v", [1])
print v1.name    # 输出v:0。“v”为变量的名称，“:0”表示这个变量是生成变量这个运算
                  # 的第一个结果。

with tf.variable_scope("foo"):
    v2 = tf.get_variable("v", [1])
    print v2.name # 输出foo/v:0。在tf.variable_scope中创建的变量，名称前面会
                  # 加入命名空间的名称，并通过/来分隔命名空间的名称和变量的名称。

with tf.variable_scope("foo"):
    with tf.variable_scope("bar"):
        v3 = tf.get_variable("v", [1])
        print v3.name    # 输出foo/bar/v:0。命名空间可以嵌套，同时变量的名称也会加
                          # 入所有命名空间的名称作为前缀。

    v4 = tf.get_variable("v1", [1])
    print v4.name    # 输出foo/v1:0。当命名空间退出之后，变量名称也就不会再被加入
                    # 其前缀了。

# 创建一个名称为空的命名空间，并设置reuse=True。
with tf.variable_scope("", reuse=True):
```

```

v5 = tf.get_variable("foo/bar/v", [1]) # 可以直接通过带命名空间名称的变量名
                                         # 来获取其他命名空间下的变量。比如这
                                         # 里通过指定名称 foo/bar/v 来获取在
                                         # 命名空间 foo/bar/ 中创建的变量。
print v5 == v3                          # 输出 True。
v6 = tf.get_variable("foo/v1", [1])
print v6 == v4                          # 输出 True。

```

通过 `tf.variable_scope` 和 `tf.get_variable` 函数，以下代码对 5.2.1 小节中定义的计算前向传播结果的函数做了一些改进。

```

def inference(input_tensor, reuse=False):
    # 定义第一层神经网络的变量和前向传播过程。
    with tf.variable_scope('layer1', reuse=reuse):
        # 根据传进来的 reuse 来判断是创建新变量还是使用已经创建好的。在第一次构造网
        # 络时需要创建新的变量，以后每次调用这个函数都直接使用 reuse=True 就不需
        # 要每次将变量传进来了。
        weights = tf.get_variable("weights", [INPUT_NODE, LAYER1_NODE],
                                   initializer=tf.truncated_normal_initializer(stddev=0.1))
        biases = tf.get_variable("biases", [LAYER1_NODE],
                                   initializer=tf.constant_initializer(0.0))
        layer1 = tf.nn.relu(tf.matmul(input_tensor, weights) + biases)

    # 类似地定义第二层神经网络的变量和前向传播过程。
    with tf.variable_scope('layer2', reuse=reuse):
        weights = tf.get_variable("weights", [LAYER1_NODE, OUTPUT_NODE],
                                   initializer=tf.truncated_normal_initializer(stddev=0.1))
        biases = tf.get_variable("biases", [OUTPUT_NODE],
                                   initializer=tf.constant_initializer(0.0))
        layer2 = tf.matmul(layer1, weights) + biases
    # 返回最后的前向传播结果。
    return layer2

x = tf.placeholder(tf.float32, [None, INPUT_NODE], name='x-input')
y = inference(x)

# 在程序中需要使用训练好的神经网络进行推导时，可以直接调用 inference(new_x, True)。
# 如果需要使用滑动平均模型可以参考 5.2.1 小节中使用的代码，把计算滑动平均的类传到
# inference 函数中即可。获取或者创建变量的部分不需要改变。
new_x = ...
new_y = inference(new_x, True)

```

使用上面这段代码所示的方式，就不再需要将所有变量都作为参数传递到不同的函数中了。当神经网络结构更加复杂、参数更多时，使用这种变量管理的方式将大大提高程序

的可读性。

5.4 TensorFlow 模型持久化

在 5.2.1 小节中给出的样例代码在训练完成之后就直接退出了，并没有将训练得到的模型保存下来方便下次直接使用。为了让训练结果可以复用，需要将训练得到的神经网络模型持久化。5.4.1 小节将介绍通过 TensorFlow 程序来持久化一个训练好的模型，并从持久化之后的模型文件中还原被保存的模型。然后 5.4.2 小节将介绍 TensorFlow 持久化的工作原理和持久化之后文件中的数据格式。

5.4.1 持久化代码实现

TensorFlow 提供了一个非常简单的 API 来保存和还原一个神经网络模型。这个 API 就是 `tf.train.Saver` 类。以下代码给出了保存 TensorFlow 计算图的方法。

```
import tensorflow as tf

# 声明两个变量并计算它们的和。
v1 = tf.Variable(tf.constant(1.0, shape=[1]), name="v1")
v2 = tf.Variable(tf.constant(2.0, shape=[1]), name="v2")
result = v1 + v2

init_op = tf.initialize_all_variables()
# 声明 tf.train.Saver 类用于保存模型。
saver = tf.train.Saver()

with tf.Session() as sess:
    sess.run(init_op)
    # 将模型保存到/path/to/model/model.ckpt 文件。
    saver.save(sess, "/path/to/model/model.ckpt")
```

上面的代码实现了持久化一个简单的 TensorFlow 模型的功能。在这段代码中，通过 `saver.save` 函数将 TensorFlow 模型保存到了 `/path/to/model/model.ckpt` 文件中。TensorFlow 模型一般会存在后缀为 `.ckpt` 的文件中。虽然上面的程序只指定了一个文件路径，但是在这个文件目录下会出现三个文件。这是因为 TensorFlow 会将计算图的结构和图上参数取值分开保存。

上面这段代码会生成的第一个文件为 `model.ckpt.meta`，它保存了 TensorFlow 计算图的

结构。第3章中介绍过 TensorFlow 计算图的原理，这里可以简单理解为神经网络的网络结构。第二个文件为 `model.ckpt`，这个文件中保存了 TensorFlow 程序中每一个变量的取值。最后一个文件为 `checkpoint` 文件，这个文件中保存了一个目录下所有的模型文件列表。对这些文件中的具体内容，5.4.2 小节中将详细讲述。以下代码中给出了加载这个已经保存的 TensorFlow 模型的方法。

```
import tensorflow as tf

# 使用和保存模型代码中一样的方式来声明变量。
v1 = tf.Variable(tf.constant(1.0, shape=[1]), name="v1")
v2 = tf.Variable(tf.constant(2.0, shape=[1]), name="v2")
result = v1 + v2

saver = tf.train.Saver()

with tf.Session() as sess:
    # 加载已经保存的模型，并通过已经保存的模型中变量的值来计算加法。
    saver.restore(sess, "/path/to/model/model.ckpt")
    print sess.run(result)
```

这段加载模型的代码基本上和保存模型的代码是一样的。在加载模型的程序中也是先定义了 TensorFlow 计算图上的所有运算，并声明了一个 `tf.train.Saver` 类。两段代码唯一不同的是，在加载模型的代码中没有运行变量的初始化过程，而是将变量的值通过已经保存的模型加载进来。如果不希望重复定义图上的运算，也可以直接加载已经持久化的图。以下代码给出了一个样例。

```
import tensorflow as tf
# 直接加载持久化的图。
saver = tf.train.import_meta_graph(
    "/path/to/model/model.ckpt/model.ckpt.meta")
with tf.Session() as sess:
    saver.restore(sess, "/path/to/model/model.ckpt")
    # 通过张量的名称来获取张量。
    print sess.run(tf.get_default_graph().get_tensor_by_name("add:0"))
    # 输出[ 3.]
```

在上面给出的程序中，默认保存和加载了 TensorFlow 计算图上定义的全部变量。但有时可能只需要保存或者加载部分变量。比如，可能有一个之前训练好的五层神经网络模型，但现在想尝试一个六层的神经网络，那么可以将前面五层神经网络中的参数直接加载到新的模型，而仅仅将最后一层神经网络重新训练。

为了保存或者加载部分变量，在声明 `tf.train.Saver` 类时可以提供一個列表来指定需要

保存或者加载的变量。比如在加载模型的代码中使用 `saver = tf.train.Saver([v1])` 命令来构建 `tf.train.Saver` 类，那么只有变量 `v1` 会被加载进来。如果运行修改后只加载了 `v1` 的代码会得到变量未初始化的错误：

```
tensorflow.python.framework.errors.FailedPreconditionError: Attempting to
use uninitialized value v2
```

因为 `v2` 没有被加载，所以 `v2` 在运行初始化之前是没有值的。除了可以选取需要被加载的变量，`tf.train.Saver` 类也支持在保存或者加载时给变量重命名。下面给出了一个简单的样例程序说明变量重命名是如何被使用的。

```
# 这里声明的变量名称和已经保存的模型中变量的名称不同。
v1 = tf.Variable(tf.constant(1.0, shape=[1]), name="other-v1")
v2 = tf.Variable(tf.constant(2.0, shape=[1]), name="other-v2")

# 如果直接使用 tf.train.Saver() 来加载模型会报变量找不到的错误。下面显示了报错信息：
# tensorflow.python.framework.errors.NotFoundError: Tensor name "other-v2"
# not found in checkpoint files /path/to/model/model.ckpt

# 使用一个字典 (dictionary) 来重命名变量就可以加载原来的模型了。这个字典指定了
# 原来名称为 v1 的变量现在加载到变量 v1 中 (名称为 other-v1)，名称为 v2 的变量
# 加载到变量 v2 中 (名称为 other-v2)。
saver = tf.train.Saver({"v1": v1, "v2": v2})
```

在这个程序中，对变量 `v1` 和 `v2` 的名称进行了修改。如果直接通过 `tf.train.Saver` 默认的构造函数来加载保存的模型，那么程序会报变量找不到的错误。因为保存时候变量的名称和加载时变量的名称不一致。为了解决这个问题，TensorFlow 可以通过字典 (dictionary) 将模型保存时的变量名和需要加载的变量联系起来。

这样做主要目的之一是方便使用变量的滑动平均值。在 4.4.3 小节中介绍了使用变量的滑动平均值可以让神经网络模型更加健壮 (robust)。在 TensorFlow 中，每一个变量的滑动平均值是通过影子变量维护的，所以要获取变量的滑动平均值实际上就是获取这个影子变量的取值。如果在加载模型时直接将影子变量映射到变量自身，那么在使用训练好的模型时就不需要再调用函数来获取变量的滑动平均值了。这样大大方便了滑动平均模型的使用。以下代码给出了一个保存滑动平均模型的样例。

```
import tensorflow as tf

v = tf.Variable(0, dtype=tf.float32, name="v")
# 在没有申明滑动平均模型时只有一个变量 v，所以下面的语句只会输出 "v:0"。
for variables in tf.all_variables():
    print variables.name
```

```

ema = tf.train.ExponentialMovingAverage(0.99)
maintain_averages_op = ema.apply(tf.all_variables())
# 在申明滑动平均模型之后, TensorFlow 会自动生成一个影子变量
# v/ExponentialMovingAverage。于是下面的语句会输出
# “v:0” 和 “v/ExponentialMovingAverage:0”。
for variables in tf.all_variables():
    print variables.name

saver = tf.train.Saver()
with tf.Session() as sess:
    init_op = tf.initialize_all_variables()
    sess.run(init_op)

    sess.run(tf.assign(v, 10))
    sess.run(maintain_averages_op)
    # 保存时, TensorFlow 会将 v:0 和 v/ExponentialMovingAverage:0 两个变量都存下来。
    saver.save(sess, "/path/to/model/model.ckpt")
    print sess.run([v, ema.average(v)]) # 输出 [10.0, 0.099999905]

```

以下代码给出了如何通过变量重命名直接读取变量的滑动平均值。从下面程序的输出可以看出, 读取的变量 `v` 的值实际上是上面代码中变量 `v` 的滑动平均值。通过这个方法, 就可以使用完全一样的代码来计算滑动平均模型前向传播的结果。

```

v = tf.Variable(0, dtype=tf.float32, name="v")
# 通过变量重命名将原来变量 v 的滑动平均值直接赋值给 v。
saver = tf.train.Saver({"v/ExponentialMovingAverage": v})
with tf.Session() as sess:
    saver.restore(sess, "/path/to/model/model.ckpt")
    print sess.run(v) # 输出 0.099999905, 这个值就是原来模型中变量 v 的滑动平均值。

```

为了方便加载时重命名滑动平均变量, `tf.train.ExponentialMovingAverage` 类提供了 `variables_to_restore` 函数来生成 `tf.train.Saver` 类所需要的变量重命名字典。以下代码给出了 `variables_to_restore` 函数的使用样例。

```

import tensorflow as tf

v = tf.Variable(0, dtype=tf.float32, name="v")
ema = tf.train.ExponentialMovingAverage(0.99)

# 通过使用 variables_to_restore 函数可以直接生成上面代码中提供的字典
# {"v/ExponentialMovingAverage": v}。
# 以下代码会输出:
# {'v/ExponentialMovingAverage': <tensorflow.python.ops.variables.Variable
# object at 0x7ff6454ddc10>}

```

```
# 其中后面的 Variable 类就代表了变量 v。
print ema.variables_to_restore()

saver = tf.train.Saver(ema.variables_to_restore())
with tf.Session() as sess:
    saver.restore(sess, "/path/to/model/model.ckpt")
    print sess.run(v) # 输出 0.099999905, 即原来模型中变量 v 的滑动平均值。
```

使用 `tf.train.Saver` 会保存运行 TensorFlow 程序所需要的全部信息, 然而有时并不需要某些信息。比如在测试或者离线预测时, 只需要知道如何从神经网络的输入层经过前向传播计算得到输出层即可, 而不需要类似于变量初始化、模型保存等辅助节点的信息。在第 6 章介绍迁移学习时, 会遇到类似的情况。而且, 将变量取值和计算图结构分成不同的文件存储有时候也不方便, 于是 TensorFlow 提供了 `convert_variables_to_constants` 函数, 通过这个函数可以将计算图中的变量及其取值通过常量的方式保存, 这样整个 TensorFlow 计算图可以统一存放在一个文件中。下面的程序提供了一个样例。

```
import tensorflow as tf
from tensorflow.python.framework import graph_util

v1 = tf.Variable(tf.constant(1.0, shape=[1]), name="v1")
v2 = tf.Variable(tf.constant(2.0, shape=[1]), name="v2")
result = v1 + v2

init_op = tf.initialize_all_variables()
with tf.Session() as sess:
    sess.run(init_op)
    # 导出当前计算图的 GraphDef 部分, 只需要这一部分就可以完成从输入层到输出层的计算
    # 过程。
    graph_def = tf.get_default_graph().as_graph_def()

    # 将图中的变量及其取值转化为常量, 同时将图中不必要的节点去掉。在 5.4.2 小节中将会看
    # 到一些系统运算也会被转化为计算图中的节点 (比如变量初始化操作)。如果只关心程序中定
    # 义的某些计算时, 和这些计算无关的节点就没有必要导出并保存了。在下面一行代码中, 最
    # 后一个参数 ['add'] 给出了需要保存的节点名称。add 节点是上面定义的两个变量相加的
    # 操作。注意这里给出的是计算节点的名称, 所以没有后面的:0①。
    output_graph_def = graph_util.convert_variables_to_constants(
        sess, graph_def, ['add'])
    # 将导出的模型存入文件。
    with tf.gfile.GFile("/path/to/model/combined_model.pb", "wb") as f:
        f.write(output_graph_def.SerializeToString())
```

① 第 3 章中介绍过张量的名称后面有:0, 表示是某个计算节点的第一个输出。而计算节点本身的名称后是没有:0 的。

通过下面的程序可以直接计算定义的加法运算的结果。当只需要得到计算图中某个节点的取值时，这提供了一个更加方便的方法。第 6 章将使用这种方法来使用训练好的模型完成迁移学习。

```
import tensorflow as tf
from tensorflow.python.platform import gfile

with tf.Session() as sess:
    model_filename = "/path/to/model/combined_model.pb"
    # 读取保存的模型文件，并将文件解析成对应的 GraphDef Protocol Buffer。
    with gfile.GFile(model_filename, 'rb') as f:
        graph_def = tf.GraphDef()
        graph_def.ParseFromString(f.read())

    # 将 graph_def 中保存的图加载到当前的图中。return_elements=["add:0"]给出了返回
    # 的张量的名称。在保存的时候给出的是计算节点的名称，所以为“add”。在加载的时候给出
    # 的是张量的名称，所以是 add:0。
    result = tf.import_graph_def(graph_def, return_elements=["add:0"])
    print sess.run(result)
```

5.4.2 持久化原理及数据格式

5.4.1 小节介绍了当调用 `saver.save` 函数时，TensorFlow 程序会自动生成 3 个文件。TensorFlow 模型的持久化就是通过这 3 个文件完成的。这一小节将详细介绍这 3 个文件中保存的内容以及数据格式。在具体介绍每一个文件之前，先简单回顾一下第 3 章中介绍过的 TensorFlow 的一些基本概念。TensorFlow 是一个通过图的形式来表述计算的编程系统，TensorFlow 程序中的所有计算都会被表达为计算图上的节点。TensorFlow 通过元图（MetaGraph）来记录计算图中节点的信息以及运行计算图中节点所需要的元数据。TensorFlow 中元图是由 MetaGraphDef Protocol Buffer 定义的^①。MetaGraphDef 中的内容就构成了 TensorFlow 持久化时的第一个文件。以下代码给出了 MetaGraphDef 类型的定义。

```
message MetaGraphDef {
    MetaInfoDef meta_info_def = 1;

    GraphDef graph_def = 2;
    SaverDef saver_def = 3;
    map<string, CollectionDef> collection_def = 4;
```

① 2.1 节中有关于 Protocol Buffer 的具体介绍。


```
map<string, SignatureDef> signature_def = 5;
}
```

从上面的代码中可以看到，元图中主要记录了 5 类信息。下面的篇幅将结合 5.4.1 小节中变量相加样例的持久化结果，逐一介绍 `MetaGraphDef` 类型的每一个属性中存储的信息。保存 `MetaGraphDef` 信息的文件默认以 `.meta` 为后缀名，在 5.4.1 小节的样例中，文件 `model.ckpt.meta` 中存储的就是元图的数据。直接运行 5.4.1 小节样例得到的是一个二进制文件，无法直接查看。为了方便调试，TensorFlow 提供了 `export_meta_graph` 函数，这个函数支持以 json 格式导出 `MetaGraphDef Protocol Buffer`。以下代码展示了如何使用这个函数。

```
import tensorflow as tf

# 定义变量相加的计算。
v1 = tf.Variable(tf.constant(1.0, shape=[1]), name="v1")
v2 = tf.Variable(tf.constant(2.0, shape=[1]), name="v2")
result1 = v1 + v2

saver = tf.train.Saver()
# 通过 export_meta_graph 函数导出 TensorFlow 计算图的元图，并保存为 json 格式。
saver.export_meta_graph("/path/to/model.ckpt.meta.json", as_text=True)
```

通过上面给出的代码，可以将 5.4.1 小节中的计算图元图以 json 的格式导出并存储在 `model.ckpt.meta.json` 文件中。下文将结合 `model.ckpt.meta.json` 文件具体介绍 TensorFlow 元图中存储的信息。

meta_info_def 属性

`meta_info_def` 属性是通过 `MetaInfoDef` 定义的，它记录了 TensorFlow 计算图中的元数据以及 TensorFlow 程序中所有使用到的运算方法的信息。下面是 `MetaInfoDef Protocol Buffer` 的定义：

```
message MetaInfoDef {
  string meta_graph_version = 1;
  OpList stripped_op_list = 2;
  google.protobuf.Any any_info = 3;
  repeated string tags = 4;
}
```

TensorFlow 计算图的元数据包括了计算图的版本号（`meta_graph_version` 属性）以及用户指定的一些标签（`tags` 属性）。如果没有在 `saver` 中特殊指定，那么这些属性都默认为空。在 `model.ckpt.meta.json` 文件中，`meta_info_def` 属性里只有 `stripped_op_list` 属性是不为空的。

`stripped_op_list` 属性记录了 TensorFlow 计算图上使用到的所有运算方法的信息。注意 `stripped_op_list` 属性保存的是 TensorFlow 运算方法的信息，所以如果某一个运算在 TensorFlow 计算图中出现了多次，那么在 `stripped_op_list` 也只会出现一次。比如在 `model.ckpt.meta.json` 文件的 `stripped_op_list` 属性中只有一个 `Variable` 运算，但这个运算在程序中被使用了两次。`stripped_op_list` 属性的类型是 `OpList`。`OpList` 类型是一个 `OpDef` 类型的列表，以下代码给出了 `OpDef` 类型的定义：

```
message OpDef {
  string name = 1;
  repeated ArgDef input_arg = 2;
  repeated ArgDef output_arg = 3;
  repeated AttrDef attr = 4;

  string summary = 5;
  string description = 6;
  OpDeprecation deprecation = 8;

  bool is_commutative = 18;
  bool is_aggregate = 16;
  bool is_stateful = 17;
  bool allows_uninitialized_input = 19;
};
```

`OpDef` 类型中前四个属性定义了一个运算最核心的信息。`OpDef` 中的第一个属性 `name` 定义了运算的名称，这也是一个运算唯一的标识符。在 TensorFlow 计算图元图的其他属性中，比如下面将要介绍的 `GraphDef` 属性，将通过运算名称来引用不同的运算。`OpDef` 的第二和第三个属性为 `input_arg` 和 `output_arg`，它们定义了运算的输入和输出。因为输入输出都可以有多个，所以这两个属性都是列表（`repeated`）。第四个属性 `attr` 给出了其他的运算参数信息。在 `model.ckpt.meta.json` 文件中总共定义了 7 个运算，下面将给出比较有代表性的一个运算来辅助说明 `OpDef` 的数据结构。

```
op {
  name: "Add"
  input_arg {
    name: "x"
    type_attr: "T"
  }
  input_arg {
    name: "y"
    type_attr: "T"
  }
  output_arg {
```

```

    name: "z"
    type_attr: "T"
  }
  attr {
    name: "T"
    type: "type"
    allowed_values {
      list {
        type: DT_HALF
        type: DT_FLOAT
        ...
      }
    }
  }
}
}
}

```

上面给出了名称为 Add 的运算。这个运算有 2 个输入和 1 个输出，输入输出属性都指定了属性 `type_attr`，并且这个属性的值为 T。在 `OpDef` 的 `attr` 属性中，必须要出现名称(name)为 T 的属性。以上样例中，这个属性指定了运算输入输出允许的参数类型(`allowed_values`)。

graph_def 属性

`graph_def` 属性主要记录了 TensorFlow 计算图上的节点信息。TensorFlow 计算图的每一个节点对应了 TensorFlow 程序中的一个运算。因为在 `meta_info_def` 属性中已经包含了所有运算的具体信息，所以 `graph_def` 属性只关注运算的连接结构。`graph_def` 属性是通过 `GraphDef Protocol Buffer` 定义的，`GraphDef` 主要包含了一个 `NodeDef` 类型的列表。以下代码给出了 `GraphDef` 和 `NodeDef` 类型中包含的信息：

```

message GraphDef {
  repeated NodeDef node = 1;
  VersionDef versions = 4;
};

message NodeDef {
  string name = 1;
  string op = 2;
  repeated string input = 3;
  string device = 4;
  map<string, AttrValue> attr = 5;
};

```

`GraphDef` 中的 `versions` 属性比较简单，它主要存储了 TensorFlow 的版本号。`GraphDef` 的主要信息都存在 `node` 属性中，它记录了 TensorFlow 计算图上所有的节点信息。和其他

属性类似，NodeDef 类型中有一个名称属性 `name`，它是一个节点的唯一标识符。在 TensorFlow 程序中可以通过节点的名称来获取相应的节点。NodeDef 类型中的 `op` 属性给出了该节点使用的 TensorFlow 运算方法的名称，通过这个名称可以在 TensorFlow 计算图元图的 `meta_info_def` 属性中找到该运算的具体信息。

NodeDef 类型中的 `input` 属性是一个字符串列表，它定义了运算的输入。`input` 属性中每个字符串的取值格式为 `node:src_output`，其中 `node` 部分给出了一个节点的名称，`src_output` 部分表明了这个输入是指定节点的第几个输出。当 `src_output` 为 0 时，可以省略 `src_output` 这个部分。比如 `node:0` 表示名称为 `node` 的节点的第一个输出，它也可以被记为 `node`。

NodeDef 类型中的 `device` 属性指定了处理这个运算的设备。运行 TensorFlow 运算的设备可以是本地机器的 CPU 或者 GPU，也可以是一台远程的机器 CPU 或者 GPU。第 10 章将具体介绍如何指定运行 TensorFlow 运算的设备。当 `device` 属性为空时，TensorFlow 在运行时会自动选取一个最合适的设备来运行这个运算。最后 NodeDef 类型中的 `attr` 属性指定了和当前运算相关的配置信息。下面列举了 `model.ckpt.meta.json` 文件中的一些计算节点来更加具体地介绍 `graph_def` 属性。

```
graph_def {
  node {
    name: "v1"
    op: "Variable"
    attr {
      key: "_output_shapes"
      value {
        list { shape { dim { size: 1 } } }
      }
    }
    attr {
      key: "dtype"
      value {
        type: DT_FLOAT
      }
    }
  }
  ...
}
node {
  name: "add"
  op: "Add"
  input: "v1/read"
  input: "v2/read"
  ...
}
```

```

node {
  name: "save/control_dependency"
  op: "Identity"
  ...
}

versions {
  producer: 9
}
}

```

上面给出了 model.ckpt.meta.json 文件中 graph_def 属性里比较有代表性的几个节点。第一个节点给出的是变量定义的运算。在 TensorFlow 中变量定义也是一个运算，这个运算的名称为 v1 (name: "v1")，运算方法的名称为 Variable (op: "Variable")。定义变量的运算可以有很多个，于是在 NodeDef 类型的 node 属性中可以有多个变量定义的节点。但定义变量的运算方法只用到了一个，于是在 MetaInfoDef 类型的 stripped_op_list 属性中只有一个名称为 Variable 的运算方法。除了指定计算图中节点的名称和运算方法，NodeDef 类型中还定义了运算相关的属性。在节点 v1 中，attr 属性指定了这个变量的维度以及类型。

给出的第二个节点是代表加法运算的节点。它指定了 2 个输入，一个为 v1/read，另一个为 v2/read。其中 v1/read 代表的节点可以读取变量 v1 的值。因为 v1 的值是节点 v1/read 的第一个输出，所以后面的:0 就可以省略了。v2/read 也类似的代表了变量 v2 的取值。以上样例文件中给出的最后一个名称为 save/control_dependency，该节点是系统在完成 TensorFlow 模型持久化过程中自动生成的一个运算。在样例文件的最后，属性 versions 给出了生成 model.ckpt.meta.json 文件时使用的 TensorFlow 版本号。

saver_def 属性

saver_def 属性中记录了持久化模型时需要用到的一些参数，比如保存到文件的文件名、保存操作和加载操作的名称以及保存频率、清理历史记录等。saver_def 属性的类型为 SaverDef，其定义如下。

```

message SaverDef {
  string filename_tensor_name = 1;
  string save_tensor_name = 2;
  string restore_op_name = 3;
  int32 max_to_keep = 4;
  bool sharded = 5;
  float keep_checkpoint_every_n_hours = 6;

  enum CheckpointFormatVersion {
    LEGACY = 0;
  }
}

```

```
V1 = 1;
V2 = 2;
}
CheckpointFormatVersion version = 7;
}
```

下面给出了 model.ckpt.meta.json 文件中 saver_def 属性的内容。

```
saver_def {
  filename_tensor_name: "save/Const:0"
  save_tensor_name: "save/control_dependency:0"
  restore_op_name: "save/restore_all"
  max_to_keep: 5
  keep_checkpoint_every_n_hours: 10000.0
}
```

filename_tensor_name 属性给出了保存文件名的张量名称，这个张量就是节点 save/Const 的第一个输出。save_tensor_name 属性给出了持久化 TensorFlow 模型的运算所对应的节点名称。从上面的文件中可以看出，这个节点就是在 graph_def 属性中给出的 save/control_dependency 节点。和持久化 TensorFlow 模型运算对应的是加载 TensorFlow 模型的运算，这个运算的名称由 restore_op_name 属性指定。max_to_keep 属性和 keep_checkpoint_every_n_hours 属性设定了 tf.train.Saver 类清理之前保存的模型的策略。比如当 max_to_keep 为 5 的时候，在第六次调用 saver.save 时，第一次保存的模型就会被自动删除。通过设置 keep_checkpoint_every_n_hours，每 n 小时可以在 max_to_keep 的基础上多保存一个模型。

collection_def 属性

在 TensorFlow 的计算图 (tf.Graph) 中可以维护不同集合，而维护这些集合的底层实现就是通过 collection_def 这个属性。collection_def 属性是一个从集合名称到集合内容的映射，其中集合名称为字符串，而集合内容为 CollectionDef Protocol Buffer。以下代码给出了 CollectionDef 类型的定义。

```
message CollectionDef {
  message NodeList {
    repeated string value = 1;
  }

  message BytesList {
    repeated bytes value = 1;
  }

  message Int64List {
```

```

    repeated int64 value = 1 [packed = true];
  }

  message FloatList {
    repeated float value = 1 [packed = true];
  }

  message AnyList {
    repeated google.protobuf.Any value = 1;
  }

  oneof kind {
    NodeList node_list = 1;
    BytesList bytes_list = 2;
    Int64List int64_list = 3;
    FloatList float_list = 4;
    AnyList any_list = 5;
  }
}

```

通过上面的定义可以看出，TensorFlow 计算图上的集合主要可以维护 4 类不同的集合。NodeList 用于维护计算图上节点的集合。BytesList 可以维护字符串或者序列化之后的 Protocol Buffer 的集合。比如张量是通过 Protocol Buffer 表示的，而张量的集合是通过 BytesList 维护的，我们将在 model.ckpt.meta.json 文件中看到具体样例。Int64List 用于维护整数集合，FloatList 用于维护实数集合。下面给出了 model.ckpt.meta.json 文件中 collection_def 属性的内容。

```

collection_def {
  key: "trainable_variables"
  value {
    bytes_list {
      value: "\n\004v1:0\022\tv1/Assign\032\tv1/read:0"
      value: "\n\004v2:0\022\tv2/Assign\032\tv2/read:0"
    }
  }
}
collection_def {
  key: "variables"
  value {
    bytes_list {
      value: "\n\004v1:0\022\tv1/Assign\032\tv1/read:0"
      value: "\n\004v2:0\022\tv2/Assign\032\tv2/read:0"
    }
  }
}

```


从上面的文件可以看出样例程序中维护了两个集合。一个是所有变量的集合，这个集合的名称为 `variables`。另外一个为可训练变量的集合，名为 `trainable_variables`。在样例程序中，这两个集合中的元素是一样的，都是变量 `v1` 和 `v2`。它们都是系统自动维护的^①。

通过对 `MetaGraphDef` 类型中主要属性的讲解，本小节已经介绍了 TensorFlow 模型持久化得到的第一个文件中的内容。除了持久化 TensorFlow 计算图的结构，持久化 TensorFlow 中变量的取值也是非常重要的一个部分。5.4.1 小节中使用 `tf.Saver` 得到的 `model.ckpt` 文件就保存了所有变量的取值。这个文件是通过 `SSTable` 格式存储的，可以大致理解为就是一个 `(key, value)` 列表。

`model.ckpt` 文件中列表的第一行描述了文件的元信息，比如在这个文件中存储的变量列表。列表剩下的每一行保存了一个变量的片段，变量片段的信息是通过 `SavedSlice Protocol Buffer` 定义的。`SavedSlice` 类型中保存了变量的名称、当前片段的信息以及变量取值。TensorFlow 提供了 `tf.train.NewCheckpointReader` 类来查看 `model.ckpt` 文件中保存的变量信息。以下代码展示了如何使用 `tf.train.NewCheckpointReader` 类。

```
import tensorflow as tf

# tf.train.NewCheckpointReader 可以读取 checkpoint 文件中保存的所有变量。
reader = tf.train.NewCheckpointReader('/path/to/model/model.ckpt')

# 获取所有变量列表。这个是一个从变量名到变量维度的字典。
all_variables = reader.get_variable_to_shape_map()
for variable_name in all_variables:
    # variable_name 为变量名称，all_variables[variable_name] 为变量的维度。
    print variable_name, all_variables[variable_name]

# 获取名称为 v1 的变量的取值。
print "Value for variable v1 is ", reader.get_tensor("v1")

'''
这个程序将输出：
v1 [1]          # 变量 v1 的维度为 [1]。
v2 [1]          # 变量 v2 的维度为 [1]。
Value for variable v1 is [ 1.] # 变量 v1 的取值为 1。
'''
```

最后一个文件的名称是固定的，叫 `checkpoint`。这个文件是 `tf.train.Saver` 类自动生成且自动维护的。在 `checkpoint` 文件中维护了由一个 `tf.train.Saver` 类持久化的所有 TensorFlow

^① 第 3 章中有更加详细的关于 TensorFlow 自动维护的集合的介绍。

模型文件的文件名。当某个保存的 TensorFlow 模型文件被删除时，这个模型所对应的文件名也会从 checkpoint 文件中删除。checkpoint 中内容的格式为 CheckpointState Protocol Buffer，下面给出了 CheckpointState 类型的定义。

```
message CheckpointState {
  string model_checkpoint_path = 1;
  repeated string all_model_checkpoint_paths = 2;
}
```

model_checkpoint_path 属性保存了最新的 TensorFlow 模型文件的文件名。all_model_checkpoint_paths 属性列出了当前还没有被删除的所有 TensorFlow 模型文件的文件名。下面给出了通过 5.4.1 节中样例程序生成的 checkpoint 文件。

```
model_checkpoint_path: "/path/to/model/model.ckpt"
all_model_checkpoint_paths: "/path/to/model/model.ckpt"
```

5.5 TensorFlow 最佳实践样例程序

在 5.2.1 小节中已经给出了一个完整的 TensorFlow 程序来解决 MNIST 问题。然而这个程序的可扩展性并不好。如在 5.3 节中提到的，计算前向传播的函数需要将所有变量都传入，当神经网络的结构变得更加复杂、参数更多时，程序可读性会变得非常差。而且这种方式会导致程序中有大量的冗余代码，降低编程的效率。5.2.1 小节给出的程序的另外一个问题是没有持久化训练好的模型。当程序退出时，训练好的模型也就无法再使用了，这导致得到的模型无法被重用。更严重的问题是，一般神经网络模型训练的时间都比较长，少则几个小时，多则几天甚至几周。如果在训练过程中程序死机了，那么没有保存训练的中间结果会浪费大量的时间和资源。所以，在训练的过程中需要每隔一段时间保存一次模型训练的中间结果。

结合 5.3 节中介绍的变量管理机制和 5.4 节中介绍的 TensorFlow 模型持久化机制，本节中将介绍一个 TensorFlow 训练神经网络模型的最佳实践。将训练和测试分成两个独立的程序，这可以使得每一个组件更加灵活。比如训练神经网络的程序可以持续输出训练好的模型，而测试程序可以每隔一段时间检验最新模型的正确率，如果模型效果更好，则将这个模型提供给产品使用。除了将不同功能模块分开，本节还将前向传播的过程抽象成一个单独的库函数。因为神经网络的前向传播过程在训练和测试的过程中都会用到，所以通过库函数的方式使用起来既可以更加方便，又可以保证训练和测试过程中使用的前向传播方法一定是一致的。

本节将提供重构之后的程序来解决 MNIST 问题。重构之后的代码将会被拆成 3 个程序，

第一个是 `mnist_inference.py`，它定义了前向传播的过程以及神经网络中的参数。第二个是 `mnist_train.py`，它定义了神经网络的训练过程。第三个是 `mnist_eval.py`，它定义了测试过程。以下代码给出了 `mnist_inference.py` 中的内容。

```
# -*- coding: utf-8 -*-
import tensorflow as tf

# 定义神经网络结构相关的参数。
INPUT_NODE = 784
OUTPUT_NODE = 10
LAYER1_NODE = 500

# 通过 tf.get_variable 函数来获取变量。在训练神经网络时会创建这些变量；在测试时会通
# 过保存的模型加载这些变量的取值。而且更加方便的是，因为可以在变量加载时将滑动平均变量
# 重命名，所以可以直接通过同样的名字在训练时使用变量自身，而在测试时使用变量的滑动平
# 均值。在这个函数中也会将变量的正则化损失加入损失集合。
def get_weight_variable(shape, regularizer):
    weights = tf.get_variable(
        "weights", shape,
        initializer=tf.truncated_normal_initializer(stddev=0.1))

    # 当给出了正则化生成函数时，将当前变量的正则化损失加入名字为 losses 的集合。在这里
    # 使用了 add_to_collection 函数将一个张量加入一个集合，而这个集合的名称为 losses。
    # 这是自定义的集合，不在 TensorFlow 自动管理的集合列表中。
    if regularizer != None:
        tf.add_to_collection('losses', regularizer(weights))
    return weights

# 定义神经网络的前向传播过程。
def inference(input_tensor, regularizer):
    # 声明第一层神经网络的变量并完成前向传播过程。
    with tf.variable_scope('layer1'):
        # 这里通过 tf.get_variable 或 tf.Variable 没有本质区别，因为在训练或是测试中
        # 没有在同一个程序中多次调用这个函数。如果在同一个程序中多次调用，在第一次调用
        # 之后需要将 reuse 参数设置为 True。
        weights = get_weight_variable(
            [INPUT_NODE, LAYER1_NODE], regularizer)
        biases = tf.get_variable(
            "biases", [LAYER1_NODE],
            initializer=tf.constant_initializer(0.0))
        layer1 = tf.nn.relu(tf.matmul(input_tensor, weights) + biases)

    # 类似的声明第二层神经网络的变量并完成前向传播过程。
    with tf.variable_scope('layer2'):
```

```

weights = get_weight_variable(
    [LAYER1_NODE, OUTPUT_NODE], regularizer)
biases = tf.get_variable(
    "biases", [OUTPUT_NODE],
    initializer=tf.constant_initializer(0.0))
layer2 = tf.matmul(layer1, weights) + biases

# 返回最后前向传播的结果。
return layer2

```

在这段代码中定了神经网络的前向传播算法。无论是训练时还是测试时，都可以直接调用 `inference` 这个函数，而不用关心具体的神经网络结构。使用定义好的前向传播过程，以下代码给出了神经网络的训练程序 `mnist_train.py`。

```

# -*- coding: utf-8 -*-
import os

import tensorflow as tf
from tensorflow.examples.tutorials.mnist import input_data

# 加载mnist_inference.py中定义的常量和前向传播的函数。
import mnist_inference

# 配置神经网络的参数。
BATCH_SIZE = 100
LEARNING_RATE_BASE = 0.8
LEARNING_RATE_DECAY = 0.99
REGULARAZTION_RATE = 0.0001
TRAINING_STEPS = 30000
MOVING_AVERAGE_DECAY = 0.99
# 模型保存的路径和文件名。
MODEL_SAVE_PATH = "/path/to/model/"
MODEL_NAME = "model.ckpt"

def train(mnist):
    # 定义输入输出placeholder。
    x = tf.placeholder(
        tf.float32, [None, mnist_inference.INPUT_NODE], name='x-input')
    y_ = tf.placeholder(
        tf.float32, [None, mnist_inference.OUTPUT_NODE], name='y-input')

    regularizer = tf.contrib.layers.l2_regularizer(REGULARAZTION_RATE)
    # 直接使用mnist_inference.py中定义的前向传播过程。
    y = mnist_inference.inference(x, regularizer)

```

```

global_step = tf.Variable(0, trainable=False)

# 和 5.2.1 小节样例中类似地定义损失函数、学习率、滑动平均操作以及训练过程。
variable_averages = tf.train.ExponentialMovingAverage(
    MOVING_AVERAGE_DECAY, global_step)
variables_averages_op = variable_averages.apply(
    tf.trainable_variables())
cross_entropy = tf.nn.sparse_softmax_cross_entropy_with_logits(
    y, tf.argmax(y, 1))
cross_entropy_mean = tf.reduce_mean(cross_entropy)
loss = cross_entropy_mean + tf.add_n(tf.get_collection('losses'))
learning_rate = tf.train.exponential_decay(
    LEARNING_RATE_BASE,
    global_step,
    mnist.train.num_examples / BATCH_SIZE,
    LEARNING_RATE_DECAY)
train_step = tf.train.GradientDescentOptimizer(learning_rate)\
    .minimize(loss, global_step=global_step)
with tf.control_dependencies([train_step, variables_averages_op]):
    train_op = tf.no_op(name='train')

# 初始化 TensorFlow 持久化类。
saver = tf.train.Saver()
with tf.Session() as sess:
    tf.initialize_all_variables().run()

    # 在训练过程中不再测试模型在验证数据上的表现，验证和测试的过程将会有个独
    # 立的程序来完成。
    for i in range(TRAINING_STEPS):
        xs, ys = mnist.train.next_batch(BATCH_SIZE)
        _, loss_value, step = sess.run([train_op, loss, global_step],
            feed_dict={x: xs, y: ys})

        # 每 1000 轮保存一次模型。
        if i % 1000 == 0:
            # 输出当前的训练情况。这里只输出了模型在当前训练 batch 上的损失函
            # 数大小。通过损失函数的大小可以大概了解训练的情况。在验证数据集上的
            # 正确率信息会有一个单独的程序来生成。
            print("After %d training step(s), loss on training "
                  "batch is %g." % (step, loss_value))
            # 保存当前的模型。注意这里给出了 global_step 参数，这样可以让每个被
            # 保存模型的文件名末尾加上训练的轮数，比如“model.ckpt-1000”表示
            # 训练 1000 轮之后得到的模型。
            saver.save(
                sess, os.path.join(MODEL_SAVE_PATH, MODEL_NAME),

```



```

        global_step=global_step)

def main(argv=None):
    mnist = input_data.read_data_sets("/tmp/data", one_hot=True)
    train(mnist)

if __name__ == '__main__':
    tf.app.run()

```

运行上面的程序，可以得到类似下面的结果。

```

~/mnist$ python mnist_train.py
Extracting /tmp/data/train-images-idx3-ubyte.gz
Extracting /tmp/data/train-labels-idx1-ubyte.gz
Extracting /tmp/data/t10k-images-idx3-ubyte.gz
Extracting /tmp/data/t10k-labels-idx1-ubyte.gz
After 1 training step(s), loss on training batch is 3.32075.
After 1001 training step(s), loss on training batch is 0.241039.
After 2001 training step(s), loss on training batch is 0.227391.
After 3001 training step(s), loss on training batch is 0.138462.
After 4001 training step(s), loss on training batch is 0.132074.
After 5001 training step(s), loss on training batch is 0.103472.
...

```

在新的训练代码中，不再将训练和测试跑在一起。训练过程中，每 1000 轮输出一次在当前训练 batch 上损失函数的大小来大致估计训练的效果。在上面的程序中，每 1000 轮保存一次训练好的模型，这样可以通过一个单独的测试程序，更加方便地在滑动平均模型上做测试。以下代码给出了测试程序 `mnist_eval.py`。

```

# -*- coding: utf-8 -*-
import time
import tensorflow as tf
from tensorflow.examples.tutorials.mnist import input_data

# 加载 mnist_inference.py 和 mnist_train.py 中定义的常量和函数。
import mnist_inference
import mnist_train

# 每 10 秒加载一次最新的模型，并在测试数据上测试最新模型的正确率。
EVAL_INTERVAL_SECS = 10

def evaluate(mnist):
    with tf.Graph().as_default() as g:
        # 定义输入输出的格式。
        x = tf.placeholder(

```



```

        tf.float32, [None, mnist_inference.INPUT_NODE], name='x-input')
    y_ = tf.placeholder(
        tf.float32, [None, mnist_inference.OUTPUT_NODE], name='y-input')
    validate_feed = {x: mnist.validation.images,
                     y: mnist.validation.labels}

    # 直接通过调用封装好的函数来计算前向传播的结果。因为测试时不关注正则化损失的值，
    # 所以这里用于计算正则化损失的函数被设置为 None。
    y = mnist_inference.inference(x, None)

    # 使用前向传播的结果计算正确率。如果需要对未知的样例进行分类，那么使用
    # tf.argmax(y, 1) 就可以得到输入样例的预测类别了。
    correct_prediction = tf.equal(tf.argmax(y, 1), tf.argmax(y_, 1))
    accuracy = tf.reduce_mean(tf.cast(correct_prediction, tf.float32))

    # 通过变量重命名的方式来加载模型，这样在前向传播的过程中就不需要调用求滑动平均
    # 的函数来获取平均值了。这样就可以完全共用 mnist_inference.py 中定义的
    # 前向传播过程。
    variable_averages = tf.train.ExponentialMovingAverage(
        mnist_train.MOVING_AVERAGE_DECAY)
    variables_to_restore = variable_averages.variables_to_restore()
    saver = tf.train.Saver(variables_to_restore)

    # 每隔 EVAL_INTERVAL_SECS 秒调用一次计算正确率的过程以检测训练过程中正确率的
    # 变化。
    while True:
        with tf.Session() as sess:
            # tf.train.get_checkpoint_state 函数会通过 checkpoint 文件自动
            # 找到目录中最新模型的文件名。
            ckpt = tf.train.get_checkpoint_state(
                mnist_train.MODEL_SAVE_PATH)
            if ckpt and ckpt.model_checkpoint_path:
                # 加载模型。
                saver.restore(sess, ckpt.model_checkpoint_path)
                # 通过文件名得到模型保存时迭代的轮数。
                global_step = ckpt.model_checkpoint_path\
                    .split('/')[-1].split('-')[-1]
                accuracy_score = sess.run(accuracy,
                                         feed_dict=validate_feed)
                print("After %s training step(s), validation "
                      "accuracy = %g" % (global_step, accuracy_score))
            else:
                print('No checkpoint file found')
                return

```

```

        time.sleep(EVAL_INTERVAL_SECS)

def main(argv=None):
    mnist = input_data.read_data_sets("/tmp/data", one_hot=True)
    evaluate(mnist)

if __name__ == '__main__':
    tf.app.run()

```

上面给出的 `mnist_eval.py` 程序会每隔 10 秒运行一次,每次运行都是读取最新保存的模型,并在 MNIST 验证数据集上计算模型的正确率。如果需要离线预测未知数据的类别(比如这个样例程序可以判断手写体数字图片中所包含的数字),只需要将计算正确率的部分改为答案输出即可。运行 `mnist_eval.py` 程序可以得到类似下面的结果。注意因为这个程序每 10 秒自动运行一次,而训练程序不一定每 10 秒输出一个新模型,所以在下面的结果中会发现有些模型被测试了多次。一般在解决真实问题时,不会这么频繁地运行评测程序。

```

~/mnist$ python mnist_eval.py
Extracting ./tmp/data/train-images-idx3-ubyte.gz
Extracting ./tmp/data/train-labels-idx1-ubyte.gz
Extracting ./tmp/data/t10k-images-idx3-ubyte.gz
Extracting ./tmp/data/t10k-labels-idx1-ubyte.gz
After 1 training step(s), test accuracy = 0.1282
After 1001 training step(s), validation accuracy = 0.9769
After 1001 training step(s), validation accuracy = 0.9769
After 2001 training step(s), validation accuracy = 0.9804
After 3001 training step(s), validation accuracy = 0.982
After 4001 training step(s), validation accuracy = 0.983
After 5001 training step(s), validation accuracy = 0.9829
After 6001 training step(s), validation accuracy = 0.9832
After 6001 training step(s), validation accuracy = 0.9832
...

```

小结

本章通过 MNIST 数据集验证了第 4 章介绍的神经网络优化方法,同时也给出了使用 TensorFlow 解决 MNIST 问题的最佳实践样例程序。首先在本章的 5.1 节中大致讲解了 MNIST 数据集的基本情况,也介绍了 TensorFlow 提供的一个类让处理 MNIST 数据集更加方便。然后 5.2 节给出了一个完整的 TensorFlow 程序来实现第 4 章中提到的所有优化方法。通过此程序,对比了不同优化算法对模型在测试数据集上正确率的影响。在 MNIST 数据集

上,可以明显地观察到神经网络的结构对最终结果的影响是巨大的,使用了激活函数和隐藏层的神经网络要远远好于没有激活函数或者没有隐藏层的神经网络。下面的第 6 章将介绍神经网络中一个非常常用的结构——卷积网络。通过卷积网络可以进一步提高神经网络模型在 MNIST 数据集上的正确率。对于其他的优化方法,虽然在 MNIST 数据集上对于正确率的提高有限,但是通过进一步的分析,验证了它们确实可以解决第 4 章中提到的问题。这一节也提出了在一个更加复杂数据集上,这些优化算法可以降低大约 10% 的错误率。

在 5.3 和 5.4 节中提出了 5.2 节中 TensorFlow 程序实现的一些不足之处,并介绍了 TensorFlow 的最佳实践来解决这些不足。5.3 节指出当神经网络的结构变得更加复杂、变量更多之后,通过引用的方式传递变量会大大降低程序的可读性。为了解决这个问题,5.3 节介绍了 TensorFlow 中利用变量名称来创建/获取变量的机制。通过这个机制可以完全将前向传播的过程抽象出来,使得训练和测试时不需要关心神经网络的结构或是参数。5.2 节中给出的训练程序另外一个问题就是没有将训练好的模型持久化。5.4 节介绍了 TensorFlow 保存模型的方法以及 TensorFlow 模型持久化的原理和数据的格式。综合 5.3 和 5.4 节中提出的问题,在 5.5 节中给出了一个通过 TensorFlow 解决 MNIST 问题的最佳实践样例程序。这个样例将神经网络的训练、测试和使用拆分成了不同的程序,并且将神经网络的前向传播过程抽象成了一个独立的库函数。通过这种方式可以将训练过程和测试、使用过程解耦合,从而使得整个流程更加灵活。

第 6 章 图像识别与卷积神经网络

在第 5 章中，通过 MNIST 数据集验证了第 4 章介绍的神经网络设计与优化的方法。从实验的结果可以看出，神经网络的结构会对神经网络的准确率产生巨大的影响。本章将介绍一个非常常用的神经网络结构——卷积神经网络（Convolutional Neural Network, CNN）。卷积神经网络的应用非常广泛，在自然语言处理^①、医药发现^②、灾难气候发现^③甚至围棋人工智能程序^④中都有应用。本章将主要通过卷积神经网络在图像识别上的应用来讲解卷积神经网络的基本原理以及如何使用 TensorFlow 实现卷积神经网络。

首先 6.1 节将介绍图像识别领域解决的问题以及图像识别领域中经典的数据集。然后 6.2 节将介绍卷积神经网络的主体思想和整体架构。接着 6.3 节将详细讲解卷积层和池化层的网络结构，以及 TensorFlow 对这些网络结构的支持。在 6.4 节中将通过两个经典的卷积神经网络模型来介绍如何设计卷积神经网络的架构以及如何设置每一层神经网络的配置。这一节将通过 TensorFlow 实现 LeNet-5 模型，并介绍 TensorFlow-Slim 来实现更加复杂的 Inception-v3 模型中的 Inception 模块。最后在 6.5 节中将介绍如何通过 TensorFlow 实现卷积神经网络的迁移学习。

① 详情请参考论文：*Learning Semantic Representations Using Convolutional Neural Networks for Web Search*、*A Deep Architecture for Semantic Parsing*、*A Convolutional Neural Network for Modelling Sentences* 及 *Convolutional Neural Networks for Sentence Classification*。

② 参见：Wallach I, Dzamba M, Heifets A. *AtomNet: A Deep Convolutional Neural Network for Bioactivity Prediction in Structure-based Drug Discovery* [J]. *Mathematische Zeitschrift*, 2015.

③ 参见：Liu Y, Racah E, Prabhat, et al. *Application of Deep Convolutional Neural Networks for Detecting Extreme Weather in Climate Datasets* [J]. 2016.

④ 参见：Clark C, Storkey A. *Teaching Deep Convolutional Neural Networks to Play Go* [J]. *Eprint Arxiv*, 2015.

6.1 图像识别问题简介及经典数据集

视觉是人类认识世界非常重要的一种知觉。对于人类来说,通过视觉来识别手写体数字、识别图片中的物体或者找出图片中人脸的轮廓都是非常简单的任务。然而对于计算机而言,让计算机识别图片中的内容就不是一件容易的事情了。图像识别问题希望借助计算机程序来处理、分析和理解图片中的内容,使得计算机可以从图片中自动识别各种不同模式的目标和对像。比如在第 5 章中介绍的 MNIST 数据集就是通过计算机来识别图片中的手写体数字。图像识别问题作为人工智能的一个重要领域,在最近几年已经取得了很多突破性的进展。本章将要介绍的卷积神经网络就是这些突破性进展背后的最主要技术支持。图 6-1 中显示了图像识别的主流技术在 MNIST 数据集上的错误率随着年份的发展趋势图。




图 6-1 不同算法在 MNIST 数据集上最好表现变化趋势图^{①②}

图 6-1 中最下方的虚线表示人工标注的错误率,其他不同的线段表示了不同算法的错误率。从图 6-1 上可以看出,相比其他算法,卷积神经网络可以得到更低的错误率。而且通过卷积神经网络达到的错误率已经非常接近人工标注的错误率了。在 MNIST 数据集的一万个测试数据上,最好的深度学习算法只会比人工识别多错一张图片。

MNIST 手写体识别数据集是一个相对简单的数据集,在其他更加复杂的图像识别数据

① 数字来源于 <http://yann.lecun.com/exdb/mnist>。

② 人工标注错误率参见: Simard P, Lecun Y, Denker J S. *Efficient Pattern Recognition Using a New Transformation Distance* [M]// *Advances in Neural Information Processing Systems (NIPS 1992)*. 1993.

集上,卷积神经网络有更加突出的表现。Cifar 数据集就是一个影响力很大的图像分类数据集。Cifar 数据集分为了 Cifar-10 和 Cifar-100 两个问题,它们都是图像词典项目 (Visual Dictionary)^①中 800 万张图片的一个子集。Cifar 数据集中的图片为 32×32 的彩色图片,这些图片是由 Alex Krizhevsky 教授、Vinod Nair 博士和 Geoffrey Hinton 教授整理的。

Cifar-10 问题收集了来自 10 个不同种类的 60000 张图片。图 6-2 的左侧显示了 Cifar-10 数据集中的每一个种类中的一些样例图片以及这些种类的类别名称,图 6-2 的右侧给出 Cifar-10 中一张飞机的图像。因为图像的像素仅为 32×32 ,所以放大之后图片是比较模糊的,但隐约还是可以看出飞机的轮廓。Cifar 官网 <https://www.cs.toronto.edu/~kriz/cifar.html> 提供了不同格式的 Cifar 数据集下载,具体的数据格式这里不再赘述。




图 6-2 Cifar-10 数据集样例图片

和 MNIST 数据集类似, Cifar-10 中的图片大小都是固定的且每一张图片中仅包含一个种类的实体^②。但和 MNIST 相比, Cifar 数据集最大的区别在于图片由黑白变成的彩色,且分类的难度也相对更高。在 Cifar-10 数据集上,人工标注的正确率大概为 94%^③,这比 MNIST 数据集上的人工表现要低很多。图 6-3 给出了 MNIST 和 Cifar-10 数据集中比较难以分类的

① 更多关于图像词典项目的介绍可以参考其官方网站 <http://groups.csail.mit.edu/vision/TinyImages>。

② MNIST 数据集中每一张图片只包含一个数字; Cifar-10 和 Cifar-100 数据集中每一张图片只包含一个种类的物体。

③ 人工标注的准确率来自技术博客 <http://torch.ch/blog/2015/07/30/cifar.html>。

图片样例。在图 6-3 左侧的四张图片给出了 Cifar-10 数据集中比较难分类的图片，直接从图片上看，人类也很难判断图片上实体的类别。图 6-3 右侧的四张图片给出了 MNIST 数据集中难度较高的图片。在这些难度高的图片上，人类还是可以有一个比较准确的猜测。目前在 Cifar-10 数据集上最好的图像识别算法正确率为 95.59%^①，达到这个正确率的算法同样使用了卷积神经网络。




图 6-3 MNIST 和 Cifar-10 数据集中分类难度较高的样例

无论是 MNIST 数据集还是 Cifar 数据集，相比真实环境下的图像识别问题，有 2 个最大的问题。第一，现实生活中的图片分辨率要远高于 32×32 ，而且图像的分辨率也不会是固定的。第二，现实生活中的物体类别很多，无论是 10 种还是 100 种都远远不够，而且一张图片中不会只出现一个种类的物体。为了更加贴近真实环境下的图像识别问题，由斯坦福大学 (Stanford University) 的李飞飞 (Feifei Li) 教授带头整理的 ImageNet 很大程度地解决了这两个问题。

ImageNet 是一个基于 WordNet[®] 的大型图像数据库。在 ImageNet 中，将近 1500 万图片被关联到了 WordNet 的大约 20000 个名词同义词集上。目前每一个与 ImageNet 相关的 WordNet 同义词集都代表了现实世界中的一个实体，可以被认为是分类问题中的一个类别。

① 具体数字出自: Springenberg J T, Dosovitskiy A, Brox T, et al. *Striving for Simplicity: The All Convolutional Net* [J]. Eprint Arxiv, 2014.

② WordNet 是一个大型英语语义网，里面将名词、动词、形容词和副词整理成了同义词集，并标注了不同同义词集之间的关系。WordNet 具体信息可以参考 WordNet 官网: <https://wordnet.princeton.edu/>。

ImageNet 中的图片都是从互联网上爬取下来的，并且通过亚马逊的人工标注服务（Amazon Mechanical Turk）将图片分类到 WordNet 的同义词集上^①。在 ImageNet 的图片中，一张图片中可能出现多个同义词集所代表的实体。

图 6-4 展示了 ImageNet 中的一张图片，在这张图片上用几个矩形框出了不同实体的轮廓。在物体识别问题中，一般将用于框出实体的矩形称为 bounding box。在图 6-4 中总共可以找到四个实体，其中有两把椅子、一个人和一条狗。类似图 6-4 中所示，ImageNet 的部分图片中的实体轮廓也被标注了出来，以用于更加精确的图像识别。



图 6-4 ImageNet 样例图片以及标注出来的实体轮廓^②

ImageNet 每年都举办图像识别相关的竞赛（ImageNet Large Scale Visual Recognition Challenge, ILSVRC），而且每年的竞赛都会有一些不同的问题，这些问题基本涵盖了图像识别的主要研究方向。ImageNet 的官网 <http://www.image-net.org/challenges/LSVRC> 列出了历届 ILSVRC 竞赛的题目和数据集。不同年份的 ImageNet 比赛提供了不同的数据集，本书将着重介绍使用得最多的 ILSVRC2012 图像分类数据集。

ILSVRC2012 图像分类数据集的任务和 Cifar 数据集是基本一致的，也是识别图像中的主要物体。ILSVRC2012 图像分类数据集包含了来自 1000 个类别的 120 万张图片，其中每张图片属于且只属于一个类别。因为 ILSVRC2012 图像分类数据集中的图片是直接从互联

① ImageNet 中图片的具体整理和标注方式可以参考：Deng J, Dong W, Socher R, et al. *ImageNet: A large-scale hierarchical image database* [C]// Computer Vision and Pattern Recognition, 2009. CVPR 2009. IEEE Conference on. IEEE, 2009.

② 此图片来自于 ImageNet 官方网站。

网上爬取得到的，所以图片的大小从几千字节到几百万字节不等。

图 6-5 给出了不同算法在 ImageNet 图像分类数据集上的 top-5 正确率。top-N 正确率指的是图像识别算法给出前 N 个答案中有一个是正确的概率。在图像分类问题上，很多学术论文都将前 N 个答案的正确率作为比较的方法，其中 N 的取值一般为 3 或 5。从图 6-5 中可以看出，在更加复杂的 ImageNet 问题上，基于卷积神经网络的图像识别算法可以远远超过人类的表现。在图 6-5 的左侧对比了传统算法与深度学习算法的正确率。从图中可以看出，深度学习，特别是卷积神经网络，给图像识别问题带来了质的飞跃。2013 年之后，基本上所有的研究都集中到了深度学习算法上。从 6.2 节开始将具体介绍卷积神经网络的基本原理，以及如何通过 TensorFlow 实现卷积神经网络。




图 6-5 不同算法在 ImageNet ILSVRC2012 图像分类数据集上的正确率

6.2 卷积神经网络简介

在 6.1 节中介绍图像识别问题时，已经多次提到了卷积神经网络。卷积神经网络在 6.1 节中介绍的所有图像分类数据集上有非常突出的表现。在前面的章节中所介绍的神经网络每两层之间的所有结点都是有边相连的，所以本书称这种网络结构为全连接层网络结构。为了将只包含全连接层的神经网络与卷积神经网络、循环神经网络^①区分开，本书将只包含

^① 第 8 章将介绍循环神经网络。

全连接层的神经网络称之为全连接神经网络。在第4章和第5章中介绍的神经网络都为全连接神经网络。在这一节中将讲解卷积神经网络与全连接神经网络的差异，并介绍组成一个卷积神经网络的基本网络结构。图6-6显示了全连接神经网络与卷积神经网络的结构对比图。




图 6-6 全连接神经网络与卷积神经网络结构示意图

虽然图6-6中显示的全连接神经网络结构和卷积神经网络的结构直观上差异比较大，但实际上它们的整体架构是非常相似的。从图6-6中可以看出，卷积神经网络也是通过一层一层的节点组织起来的。和全连接神经网络一样，卷积神经网络中的每一个节点都是一个神经元^①。在全连接神经网络中，每相邻两层之间的节点都有边相连，于是一般会将每一层全连接层中的节点组织成一行，这样方便显示连接结构。而对于卷积神经网络，相邻两层之间只有部分节点相连，为了展示每一层神经元的维度，一般会将每一层卷积层的节点组织成一个三维矩阵。

除了结构相似，卷积神经网络的输入输出以及训练流程与全连接神经网络也基本一致。以图像分类为例，卷积神经网络的输入层就是图像的原始像素，而输出层中的每一个节点代表了不同类别的可信度。这和全连接神经网络的输入输出是一致的。类似的，第4章中介绍的损失函数以及参数的优化过程也都适用于卷积神经网络。在后面的章节中会看到，在TensorFlow中训练一个卷积神经网络的流程和训练一个全连接神经网络没有任何区别。卷积神经网络和全连接神经网络的唯一区别就在于神经网络中相邻两层的连接方式。在进一步介绍卷积神经网络的连接结构之前，本节将先介绍为什么全连接神经网络无法很好地处理图像数据。

使用全连接神经网络处理图像的最大问题在于全连接层的参数太多。对于MNIST数据，每一张图片的大小是 $28 \times 28 \times 1$ ，其中 28×28 为图片的大小， $\times 1$ 表示图像是黑白的，只有一个色彩通道。假设第一层隐藏层的节点数为500个，那么一个全连接层的神经网络将有 $28 \times 28 \times 500 + 500 = 392500$ 个参数。当图片更大时，比如在Cifar-10数据集中，图片的大小

^① 在第4章的图4-5中介绍了神经元的结构。

为 $32 \times 32 \times 3$, 其中 32×32 表示图片的大小, $\times 3$ 表示图片是通过红绿蓝三个色彩通道(channel)表示的^①。这样输入层就有 3072 个节点, 如果第一层全连接层仍然是 500 个节点, 那么这一层全链接神经网络将有 $3072 \times 500 + 500 \approx 150$ 万个参数。参数增多除了导致计算速度减慢, 还很容易导致过拟合问题。所以需要有一个更合理的神经网络结构来有效地减少神经网络中参数个数。卷积神经网络就可以达到这个目的。

图 6-7 给出了一个更加具体的卷积神经网络架构图。




图 6-7 用于图像分类问题的一种卷积神经网络架构图

在卷积神经网络的前几层中, 每一层的节点都被组织成一个三维矩阵。比如处理 Cifar-10 数据集中的图片时, 可以将输入层组织成一个 $32 \times 32 \times 3$ 的三维矩阵。图 6-7 中虚线部分展示了卷积神经网络的一个连接示意图, 从图中可以看出卷积神经网络中前几层中每一个节点只和上一层中部分的节点相连。卷积神经网络的具体连接方式将在 6.3 节中介绍。一个卷积神经网络主要由以下 5 种结构组成:

1. 输入层。输入层是整个神经网络的输入, 在处理图像的卷积神经网络中, 它一般代表了一张图片的像素矩阵。比如在图 6-7 中, 最左侧的三维矩阵就可以代表一张图片。其中三维矩阵的长和宽代表了图像的大小, 而三维矩阵的深度代表了图像的色彩通道(channel)。比如黑白图片的深度为 1, 而在 RGB 色彩模式下, 图像的深度为 3。从输入层开始, 卷积神经网络通过不同的神经网络结构将上一层的三维矩阵转化为下一层的三维矩阵, 直到最后的全连接层。

2. 卷积层。从名字就可以看出, 卷积层是一个卷积神经网络中最为重要的部分。和传统全连接层不同, 卷积层中每一个节点的输入只是上一层神经网络的一小块, 这个小块常用的大小有 3×3 或者 5×5 。卷积层试图将神经网络中的每一小块进行更加深入地分析从

^① 在 RGB 色彩模式下, 一幅完整的图像是由红色、绿色和蓝色 3 个通道组成的。因为每个通道在每个像素点上都有亮度值, 所以整个图片就可以表示成一个三维矩阵。

而得到抽象程度更高的特征。一般来说，通过卷积层处理过的节点矩阵会变得更深，所以在图 6-7 中可以看到经过卷积层之后的节点矩阵的深度会增加。

3. 池化层 (Pooling)。池化层神经网络不会改变三维矩阵的深度，但是它可以缩小矩阵的大小。池化操作可以认为是将一张分辨率较高的图片转化为分辨率较低的图片。通过池化层，可以进一步缩小最后全连接层中节点的个数，从而达到减少整个神经网络中参数的目的。

4. 全连接层。如图 6-7 所示，在经过多轮卷积层和池化层的处理之后，在卷积神经网络的最后一般会是由 1 到 2 个全连接层来给出最后的分类结果。经过几轮卷积层和池化层的处理之后，可以认为图像中的信息已经被抽象成了信息含量更高的特征。我们可以将卷积层和池化层看成自动图像特征提取的过程。在特征提取完成之后，仍然需要使用全连接层来完成分类任务。

5. Softmax 层。和第 4 章中介绍的一样，Softmax 层主要用于分类问题。通过 Softmax 层，可以得到当前样例属于不同种类的概率分布情况。


在卷积神经网络中使用到的输入层、全连接层和 Softmax 层在第 4 章中都有过详细的介绍，这里不再赘述。在下面的 6.3 节中将详细介绍卷积神经网络中特殊的两个网络结构——卷积层和池化层。

6.3 卷积神经网络常用结构

6.2 节已经大致介绍了卷积层和池化层的概念，在本节中将具体介绍这两种网络结构。在下面的两个小节中将分别介绍卷积层和池化层的网络结构以及前向传播的过程，并通过 TensorFlow 实现这些网络结构。本书中将不会介绍优化卷积神经网络的数学公式，但通过 TensorFlow 可以很容易地完成优化的过程。

6.3.1 卷积层

本小节将详细介绍卷积层的结构以及其前向传播的算法。图 6-8 中显示了卷积层神经网络结构中最重要的一部分，这个部分被称之为过滤器 (filter) 或者内核 (kernel)。因为 TensorFlow 文档中将这个结构称之为过滤器 (filter)，所以在本书中将统称这个结构为过滤器。如图 6-8 所示，过滤器可以将当前层神经网络上的一个子节点矩阵转化为下一层神经网络上的一个单位节点矩阵。单位节点矩阵指的是一个长和宽都为 1，但深度不限的节点矩阵。

图 6-8 卷积层过滤器 (filter) 结构示意图^①

在一个卷积层中，过滤器所处理的节点矩阵的长和宽都是由人工指定的，这个节点矩阵的尺寸也被称之为过滤器的尺寸。常用的过滤器尺寸有 3×3 或 5×5 。因为过滤器处理的矩阵深度和当前层神经网络节点矩阵的深度是一致的，所以虽然节点矩阵是三维的，但过滤器的尺寸只需要指定两个维度。过滤器中另外一个需要人工指定的设置是处理得到的单位节点矩阵的深度，这个设置称为过滤器的深度。注意过滤器的尺寸指的是一个过滤器输入节点矩阵的大小，而深度指的是输出单位节点矩阵的深度。如图 6-8 所示，左侧小矩阵的尺寸为过滤器的尺寸，而右侧单位矩阵的深度为过滤器的深度。6.4 节将通过一些经典卷积神经网络结构来了解如何设置每一层卷积层过滤器的尺寸和深度。

如图 6-8 所示，过滤器的前向传播过程就是通过左侧小矩阵中的节点计算出右侧单位矩阵中节点的过程。为了直观地解释过滤器的前向传播过程，在下面的篇幅中将给出一个具体的样例。在这个样例中将展示如何通过过滤器将一个 $2 \times 2 \times 3$ 的节点矩阵变化为一个 $1 \times 1 \times 5$ 的单位节点矩阵。一个过滤器的前向传播过程和全连接层相似，它总共需要 $2 \times 2 \times 3 \times 5 + 5 = 65$ 个参数，其中最后的 +5 为偏置项参数的个数。假设使用 $w_{x,y,z}^i$ 来表示对于输出单位节点矩阵中的第 i 个节点，过滤器输入节点 (x,y,z) 的权重，使用 b^i 表示第 i 个输出节点对应的偏置项参数，那么单位矩阵中的第 i 个节点的取值 $g(i)$ 为：

$$g(i) = f\left(\sum_{x=1}^2 \sum_{y=1}^2 \sum_{z=1}^3 a_{x,y,z} \times w_{x,y,z}^i + b^i\right)$$

其中 $a_{x,y,z}$ 为过滤器中节点 (x,y,z) 的取值， f 为激活函数。图 6-9 展示了在给定 a ， w^0 和 b^0 的情况下，使用 ReLU 作为激活函数时 $g(0)$ 的计算过程。在图 6-9 的左侧给出了 a 和 w^0 的取值，这里通过 3 个二维矩阵来表示一个三维矩阵的取值，其中每一个二维矩阵表示三维矩阵在某一个深度上的取值。图 6-9 中 \cdot 符号表示点积，也就是矩阵中对应元素乘积的和。图 6-9 的右侧显示了 $g(0)$ 的计算过程。如果给出 w^1 到 w^4 和 b^1 到 b^4 ，那么也可以类似地计算出 $g(1)$ 到 $g(4)$ 的取值。如果将 a 和 w^i 组织成两个向量，那么一个过滤器的计算过程

^① 此图片来自斯坦福大学在线卷积神经网络教程 <http://cs231n.github.io/convolutional-networks/>。

完全可以通过第3章中介绍的向量乘法来完成。




图 6-9 使用过滤器计算 $g(0)$ 取值的过程示意图

上面的样例已经介绍了在卷积层中计算一个过滤器的前向传播过程。卷积层结构的前向传播过程就是通过将过滤器从神经网络当前层的左上角移动到右下角，并且在移动中计算每一个对应的单位矩阵得到的。图 6-10 展示了卷积层结构前向传播的过程。为了更好地可视化过滤器的移动过程，图 6-10 中使用的节点矩阵深度都为 1。在图 6-10 中，展示了在 3×3 矩阵上使用 2×2 过滤器的卷积层前向传播过程。在这个过程中，首先将这个过滤器用于左上角子矩阵，然后移动到左下角矩阵，再到右上角矩阵，最后到右下角矩阵。过滤器每移动一次，可以计算得到一个值（当深度为 k 时会计算出 k 个值）。将这些数值拼接成一个新的矩阵，就完成了卷积层前向传播的过程。图 6-10 的右侧显示了过滤器在移动过程中计算得到的结果与新矩阵中节点的对应关系。




图 6-10 卷积层前向传播过程示意图

当过滤器的大小不为 1×1 时，卷积层前向传播得到的矩阵的尺寸要小于当前层矩阵的尺寸。如图 6-10 所示，当前层矩阵的大小为 3×3 （图 6-10 左侧矩阵），而通过卷积层前向传播算法之后，得到的矩阵大小为 2×2 （图 6-10 右侧矩阵）。为了避免尺寸的变化，可以在当前层矩阵的边界上加入全 0 填充（zero-padding）。这样可以使得卷积层前向传播结果矩阵的大小和当前层矩阵保持一致。图 6-11 显示了使用全 0 填充后卷积层前向传播过程示

意图。从图中可以看出，加入一层全 0 填充后，得到的结构矩阵大小就为 3×3 了。




图 6-11 使用了全 0 填充 (zero-padding) 的卷积层前向传播示意图^①

除了使用全 0 填充，还可以通过设置过滤器移动的步长来调整结果矩阵的大小。在图 6-10 和图 6-11 中，过滤器每次都只移动一格。图 6-12 中显示了当移动步长为 2 且使用全 0 填充时，卷积层前向传播的过程。




图 6-12 过滤器移动步长为 2 且使用全 0 填充时卷积层前向传播过程示意图

从图 6-12 上可以看出，当长和宽的步长均为 2 时，过滤器每隔 2 步计算一次结果，所以得到的结果矩阵的长和宽也就都只有原来的一半。下面的公式给出了在同时使用全 0 填充时结果矩阵的大小。

$$\begin{aligned} out_{length} &= \lceil in_{length} / stride_{length} \rceil \\ out_{width} &= \lceil in_{width} / stride_{width} \rceil \end{aligned}$$

其中 out_{height} 表示输出层矩阵的长度，它等于输入层矩阵长度除以长度方向上的步长的

^① 此处全 0 填充的方式和 TensorFlow 中实现的方式略有不同，但是原理是一样的。

向上取整值。类似的, out_{width} 表示输出层矩阵的宽度, 它等于输入层矩阵宽度除以宽度方向上的步长的向上取整值。如果不使用全 0 填充, 下面的公式给出了结果矩阵的大小。

$$out_{length} = \lceil (in_{length} - filter_{length} + 1) / stride_{length} \rceil$$

$$out_{width} = \lceil (in_{width} - filter_{width} + 1) / stride_{width} \rceil$$

在图 6-10、图 6-11 以及图 6-12 中, 只讲解了移动过滤器的方式, 没有涉及到过滤器中的参数如何设定, 所以在这些图片中结果矩阵中并没有填上具体的值。在卷积神经网络中, 每一个卷积层中使用的过滤器中的参数都是一样的。这是卷积神经网络一个非常重要的性质。从直观上理解, 共享过滤器的参数可以使得图像上的内容不受位置的影响。以 MNIST 手写体数字识别为例, 无论数字“1”出现在左上角还是右下角, 图片的种类都是不变的。因为在左上角和右下角使用的过滤器参数相同, 所以通过卷积层之后无论数字在图像上的哪个位置, 得到的结果都一样。

共享每一个卷积层中过滤器中的参数可以巨幅减少神经网络上的参数。以 Cifar-10 问题为例, 输入层矩阵的维度是 $32 \times 32 \times 3$ 。假设第一层卷积层使用尺寸为 5×5 , 深度为 16 的过滤器, 那么这个卷积层的参数个数为 $5 \times 5 \times 3 \times 16 + 16 = 1216$ 个。6.2 节中提到过, 使用 500 个隐藏节点的全连接层将有 1.5 百万个参数。相比之下, 卷积层的参数个数要远远小于全连接层。而且卷积层的参数个数和图片的大小无关, 它只和过滤器的尺寸、深度以及当前层节点矩阵的深度有关。这使得卷积神经网络可以很好地扩展到更大的图像数据上。

结合过滤器的使用方法和参数共享的机制, 图 6-13 给出了使用了全 0 填充、步长为 2 的卷积层前向传播的计算流程。




图 6-13 卷积层前向传播过程样例图

图 6-13 给出了过滤器上权重的取值以及偏置项的取值, 通过图 6-9 中所示的计算方法,

可以得到每一个格子的具体取值。下面的公式给出了左上角格子取值的计算方法，其他格子可以依次类推。

$$\text{ReLU}(0 \times 1 + 0 \times (-1) + 0 \times 0 + 1 \times 2 + 1) = \text{ReLU}(3) = 3$$

TensorFlow 对卷积神经网络提供了非常好的支持，下面的程序实现了一个卷积层的前向传播过程。从以下代码可以看出，通过 TensorFlow 实现卷积层是非常方便的。

```
# 通过 tf.get_variable 的方式创建过滤器的权重变量和偏置项变量。上面介绍了卷积层
# 的参数个数只和过滤器的尺寸、深度以及当前层节点矩阵的深度有关，所以这里声明的参数变
# 量是一个四维矩阵，前面两个维度代表了过滤器的尺寸，第三个维度表示当前层的深度，第四
# 个维度表示过滤器的深度。
filter_weight = tf.get_variable(
    'weights', [5, 5, 3, 16],
    initializer=tf.truncated_normal_initializer(stddev=0.1))
# 和卷积层的权重类似，当前层矩阵上不同位置的偏置项也是共享的，所以总共有下一层深度个不
# 同的偏置项。本样例代码中 16 为过滤器的深度，也是神经网络中下一层节点矩阵的深度。
biases = tf.get_variable(
    'biases', [16], initializer=tf.constant_initializer(0.1))

# tf.nn.conv2d 提供了一个非常方便的函数来实现卷积层前向传播的算法。这个函数的第一个输
# 入为当前层的节点矩阵。注意这个矩阵是一个四维矩阵，后面三个维度对应一个节点矩阵，第一
# 维对应一个输入 batch。比如在输入层，input[0,:,:,:]表示第一张图片，input[1,:,:,:]
# 表示第二张图片，以此类推。tf.nn.conv2d 第二个参数提供了卷积层的权重，第三个参数为不
# 同维度上的步长。虽然第三个参数提供的是一个长度为 4 的数组，但是第一维和最后一维的数字
# 要求一定是 1。这是因为卷积层的步长只对矩阵的长和宽有效。最后一个参数是填充 (padding)
# 的方法，TensorFlow 中提供 SAME 或是 VALID 两种选择。其中 SAME 表示添加全 0 填充（如
# 图 6-11 所示），“VALID”表示不添加（如图 6-10 所示）。
conv = tf.nn.conv2d(
    input, filter_weight, strides=[1, 1, 1, 1], padding='SAME')

# tf.nn.bias_add 提供了一个方便的函数给每一个节点加上偏置项。注意这里不能直接使用加
# 法，因为矩阵上不同位置上的节点都需要加上同样的偏置项。如图 6-13 所示，虽然下一层神
# 经网络的大小为 2×2，但是偏置项只有一个数（因为深度为 1），而 2×2 矩阵中的每一个值都需
# 要加上这个偏置项。
bias = tf.nn.bias_add(conv, biases)
# 将计算结果通过 ReLU 激活函数完成去线性化。
activated_conv = tf.nn.relu(bias)
```

6.3.2 池化层

6.2 节介绍过卷积神经网络的大致架构。从图 6-7 中可以看出，在卷积层之间往往会加

上一个池化层 (pooling layer)。池化层可以非常有效地缩小矩阵的尺寸^①, 从而减少最后全连接层中的参数。使用池化层既可以加快计算速度也有防止过拟合问题的作用^②。

和 6.3.1 小节中介绍的卷积层类似, 池化层前向传播的过程也是通过移动一个类似过滤器的结构完成的。不过池化层过滤器中的计算不是节点的加权和, 而是采用更加简单的最大值或者平均值运算。使用最大值操作的池化层被称之为最大池化层 (max pooling), 这是被使用得最多的池化层结构。使用平均值操作的池化层被称之为平均池化层 (average pooling)。其他池化层在实践中使用的比较少, 本书不做过多的介绍。

与卷积层的过滤器类似, 池化层的过滤器也需要人工设定过滤器的尺寸、是否使用全 0 填充以及过滤器移动的步长等设置, 而且这些设置的意义也是一样的。卷积层和池化层中过滤器移动的方式是相似的, 唯一的区别在于卷积层使用的过滤器是横跨整个深度的, 而池化层使用的过滤器只影响一个深度上的节点。所以池化层的过滤器除了在长和宽两个维度移动之外, 它还需要在深度这个维度移动。图 6-14 展示了一个最大池化层前向传播计算过程。




图 6-14 3×3×2 节点矩阵经过全 0 填充且步长为 2 的最大池化层前向传播过程示意图。

① 池化层主要用于减小矩阵的长和宽。虽然池化层也可以减小矩阵深度, 但是实践中一般不会这样使用。

② 有研究指出池化层对模型效果的影响不大, 具体细节可以参考: Springenberg J T, Dosovitskiy A, Brox T, et al. *Striving for Simplicity: The All Convolutional Net* [J]. Eprint Arxiv, 2014. 不过目前主流的卷积神经网络模型中都含有池化层。

在图 6-14 中，不同颜色或者不同线段（虚线或者实线）代表了不同的池化层过滤器。从图 6-14 中可以看出，池化层的过滤器除了在长和宽的维度上移动，它还需要在深度的维度上移动。下面的 TensorFlow 程序实现了最大池化层的前向传播算法。

```
# tf.nn.max_pool 实现了最大池化层的前向传播过程，它的参数和 tf.nn.conv2d 函数类似。
# ksize 提供了过滤器的尺寸，strides 提供了步长信息，padding 提供了是否使用全 0 填充。
pool = tf.nn.max_pool(activated_conv, ksize=[1, 3, 3, 1],
                      strides=[1, 2, 2, 1], padding='SAME')
```

对比池化层和卷积层前向传播在 TensorFlow 中的实现，可以发现函数的参数形式是相似的。在 `tf.nn.max_pool` 函数中，首先需要传入当前层的节点矩阵，这个矩阵是一个四维矩阵，格式和 `tf.nn.conv2d` 函数中的第一个参数一致。第二个参数为过滤器的尺寸。虽然给出的是一个长度为 4 的一维数组，但是这个数组的第一个和最后一个数必须为 1。这意味着池化层的过滤器是不可以跨不同输入样例或者节点矩阵深度的。在实际应用中使用得最多的池化层过滤器尺寸为 `[1,2,2,1]` 或者 `[1,3,3,1]`。

`tf.nn.max_pool` 函数的第三个参数为步长，它和 `tf.nn.conv2d` 函数中步长的意义是一样的，而且第一维和最后一维也只能为 1。这意味着在 TensorFlow 中，池化层不能减少节点矩阵的深度或者输入样例的个数。`tf.nn.max_pool` 函数的最后一个参数指定了是否使用全 0 填充。这个参数也只有两种取值——`VALID` 或者 `SAME`，其中 `VALID` 表示不使用全 0 填充，`SAME` 表示使用全 0 填充。TensorFlow 还提供了 `tf.nn.avg_pool` 来实现平均池化层。`tf.nn.avg_pool` 函数的调用格式和 `tf.nn.max_pool` 函数是一致的。

6.4 经典卷积网络模型

在 6.3 小节中介绍了卷积神经网络特有的两种网络结构——卷积层和池化层。然而，通过这些网络结构任意组合得到的神经网络有无限多种，怎样的神经网络更有可能解决真实的图像处理问题呢？这一节将介绍一些经典的卷积神经网络的网络结构。通过这些经典的卷积神经网络的网络结构可以总结出卷积神经网络结构设计的一些模式。在 6.4.1 小节中将具体介绍 LeNet-5 模型，并给出一个完整的 TensorFlow 程序来实现 LeNet-5 模型。通过这个模型，将给出卷积神经网络结构设计的一个通用模式。然后 6.4.2 小节将介绍设计卷积神经网络结构的另外一种思路——Inception 模型。这个小节将简单介绍 TensorFlow-Slim 工具，并通过这个工具实现谷歌提出的 Inception-v3 模型中的一个模块。

6.4.1 LeNet-5 模型

LeNet-5 模型是 Yann LeCun 教授于 1998 年在论文 *Gradient-based learning applied to document recognition*^①中提出的，它是第一个成功应用于数字识别问题的卷积神经网络。在 MNIST 数据集上，LeNet-5 模型可以达到大约 99.2% 的正确率。LeNet-5 模型总共有 7 层，图 6-15 展示了 LeNet-5 模型的架构。




图 6-15 LeNet-5 模型结构图^②

在下面的篇幅中将详细介绍 LeNet-5 模型每一层的结构^③。

第一层，卷积层

这一层的输入就是原始的图像像素，LeNet-5 模型接受的输入层大小为 $32 \times 32 \times 1$ 。第一个卷积层过滤器的尺寸为 5×5 ，深度为 6，不使用全 0 填充，步长为 1。因为没有使用全 0 填充，所以这一层的输出的尺寸为 $32 - 5 + 1 = 28$ ，深度为 6。这一个卷积层总共有 $5 \times 5 \times 1 \times 6 + 6 = 156$ 个参数，其中 6 个为偏置项参数。因为下一层的节点矩阵有 $28 \times 28 \times 6 = 4704$ 个节点，每个节点和 $5 \times 5 = 25$ 个当前层节点相连，所以本层卷积层总共有 $4704 \times (25 + 1) = 122304$ 个连接。

第二层，池化层

这一层的输入为第一层的输出，是一个 $28 \times 28 \times 6$ 的节点矩阵。本层采用的过滤器大小为 2×2 ，长和宽的步长均为 2，所以本层的输出矩阵大小为 $14 \times 14 \times 6$ 。原始的 LeNet-5 模型

① Lecun Y, Bottou L, Bengio Y, et al. *Gradient-based learning applied to document recognition* [J]. Proceedings of the IEEE, 1998.

② 此图片来自论文 *Gradient-based learning applied to document recognition*。

③ 论文 *GradientBased Learning Applied to Document Recognition* 提出的 LeNet-5 模型中，卷积层和池化层的实现与 6.3 节中介绍的 TensorFlow 的实现有细微的区别，本书不过多的讨论具体细节，而是着重介绍模型的整体框架。

中使用的过滤器和 6.3.2 小节介绍的有些细微差别，本书不做具体介绍。

第三层，卷积层

本层的输入矩阵大小为 $14 \times 14 \times 6$ ，使用的过滤器大小为 5×5 ，深度为 16。本层不使用全 0 填充，步长为 1。本层的输出矩阵大小为 $10 \times 10 \times 16$ 。按照标准的卷积层，本层应该有 $5 \times 5 \times 6 \times 16 + 16 = 2416$ 个参数， $10 \times 10 \times 16 \times (25 + 1) = 41600$ 个连接。

第四层，池化层

本层的输入矩阵大小为 $10 \times 10 \times 16$ ，采用的过滤器大小为 2×2 ，步长为 2。本层的输出矩阵大小为 $5 \times 5 \times 16$ 。

第五层，全连接层

本层的输入矩阵大小为 $5 \times 5 \times 16$ ，在 LeNet-5 模型的论文中将这一层称为卷积层，但是因为过滤器的大小就是 5×5 ，所以和全连接层没有区别，在之后的 TensorFlow 程序实现中也会将这一层看成全连接层。如果将 $5 \times 5 \times 16$ 矩阵中的节点拉成一个向量，那么这一层和在第 4 章中介绍的全连接层输入就一样了。本层的输出节点个数为 120，总共有 $5 \times 5 \times 16 \times 120 + 120 = 48120$ 个参数。

第六层，全连接层

本层的输入节点个数为 120 个，输出节点个数为 84 个，总共参数为 $120 \times 84 + 84 = 10164$ 个。

第七层，全连接层^①

本层的输入节点个数为 84 个，输出节点个数为 10 个，总共参数为 $84 \times 10 + 10 = 850$ 个。

上面介绍了 LeNet-5 模型每一层结构和设置，下面给出一个 TensorFlow 的程序来实现一个类似 LeNet-5 模型的卷积神经网络来解决 MNIST 数字识别问题。通过 TensorFlow 训练卷积神经网络的过程和第 5 章中介绍的训练全连接神经网络是完全一样的。损失函数的计算、反向传播过程的实现都可以复用 5.5 节中给出的 `mnist_train.py` 程序。唯一的区别在于因为卷积神经网络的输入层为一个三维矩阵，所以需要调整一下输入数据的格式：

```
# 调整输入数据 placeholder 的格式，输入为一个四维矩阵。
x = tf.placeholder(tf.float32, [
    BATCH_SIZE,                    # 第一维表示一个 batch 中样例的个数。
    mnist_inference.IMAGE_SIZE,    # 第二维和第三维表示图片的尺寸。
    mnist_inference.IMAGE_SIZE,
    mnist_inference.NUM_CHANNELS], # 第四维表示图片的深度，对于 RGB 格
                                # 式的图片，深度为 5。
    name='x-input')
...
```

① LeNet-5 模型论文中最后一层输出层的结构和全连接层有区别，但我们这用全连接层近似的表示。

```
# 类似地将输入的训练数据格式调整为一个四维矩阵,并将这个调整后的数据传入 sess.run 过程。
reshaped_xs = np.reshape(xs, (BATCH_SIZE,
                               mnist_inference.IMAGE_SIZE,
                               mnist_inference.IMAGE_SIZE,
                               mnist_inference.NUM_CHANNELS))
```

在调整完输入格式之后,只需要在程序 `mnist_inference.py` 中实现类似 LeNet-5 模型结构的前向传播过程即可。下面给出了修改后的 `mnist_inference.py` 程序。

```
# -*- coding: utf-8 -*-
import tensorflow as tf

# 配置神经网络的参数。
INPUT_NODE = 784
OUTPUT_NODE = 10

IMAGE_SIZE = 28
NUM_CHANNELS = 1
NUM_LABELS = 10

# 第一层卷积层的尺寸和深度。
CONV1_DEEP = 32
CONV1_SIZE = 5
# 第二层卷积层的尺寸和深度。
CONV2_DEEP = 64
CONV2_SIZE = 5
# 全连接层的节点个数。
FC_SIZE = 512

# 定义卷积神经网络的前向传播过程。这里添加了一个新的参数 train, 用于区分训练过程和测试
# 过程。在这个程序中将用到 dropout 方法, dropout 可以进一步提升模型可靠性并防止过拟合,
# dropout 过程只在训练时使用①。
def inference(input_tensor, train, regularizer):
    # 声明第一层卷积层的变量并实现前向传播过程。这个过程和 6.3.1 小节中介绍的一致。
    # 通过使用不同的命名空间来隔离不同层的变量,这可以让每一层中的变量命名只需要
    # 考虑在当前层的作用,而不需要担心重名的问题。和标准 LeNet-5 模型不大一样,这里
    # 定义的卷积层输入为 28×28×1 的原始 MNIST 图片像素。因为卷积层中使用了全 0 填充,
    # 所以输出为 28×28×32 的矩阵。
    with tf.variable_scope('layer1-conv1'):
        conv1_weights = tf.get_variable(
```

① 关于 dropout 的详情可以参考论文 Hinton G E, Srivastava N, Krizhevsky A, et al. *Improving neural networks by preventing co-adaptation of feature detectors*[J]. Computer Science, 2012.

```

        "weight", [CONV1_SIZE, CONV1_SIZE, NUM_CHANNELS, CONV1_DEEP],
        initializer=tf.truncated_normal_initializer(stddev=0.1))
    conv1_biases = tf.get_variable(
        "bias", [CONV1_DEEP], initializer=tf.constant_initializer(0.0))

    # 使用边长为 5，深度为 32 的过滤器，过滤器移动的步长为 1，且使用全 0 填充。
    conv1 = tf.nn.conv2d(
        input_tensor, conv1_weights, strides=[1, 1, 1, 1], padding='SAME')
    relu1 = tf.nn.relu(tf.nn.bias_add(conv1, conv1_biases))

    # 实现第二层池化层的前向传播过程。这里选用最大池化层，池化层过滤器的边长为 2，
    # 使用全 0 填充且移动的步长为 2。这一层的输入是上一层的输出，也就是 28×28×32
    # 的矩阵。输出为 14×14×32 的矩阵。
    with tf.name_scope('layer2-pool1'):
        pool1 = tf.nn.max_pool(
            relu1, ksize=[1, 2, 2, 1], strides=[1, 2, 2, 1], padding='SAME')

    # 声明第三层卷积层的变量并实现前向传播过程。这一层的输入为 14×14×32 的矩阵。
    # 输出为 14×14×64 的矩阵。
    with tf.variable_scope('layer3-conv2'):
        conv2_weights = tf.get_variable(
            "weight", [CONV2_SIZE, CONV2_SIZE, CONV1_DEEP, CONV2_DEEP],
            initializer=tf.truncated_normal_initializer(stddev=0.1))
        conv2_biases = tf.get_variable(
            "bias", [CONV2_DEEP],
            initializer=tf.constant_initializer(0.0))

        # 使用边长为 5，深度为 64 的过滤器，过滤器移动的步长为 1，且使用全 0 填充。
        conv2 = tf.nn.conv2d(
            pool1, conv2_weights, strides=[1, 1, 1, 1], padding='SAME')
        relu2 = tf.nn.relu(tf.nn.bias_add(conv2, conv2_biases))

    # 实现第四层池化层的前向传播过程。这一层和第二层的结构是一样的。这一层的输入为
    # 14×14×64 的矩阵，输出为 7×7×64 的矩阵。
    with tf.name_scope('layer4-pool2'):
        pool2 = tf.nn.max_pool(
            relu2, ksize=[1, 2, 2, 1], strides=[1, 2, 2, 1], padding='SAME')

    # 将第四层池化层的输出转化为第五层全连接层的输入格式。第四层的输出为 7×7×64 的矩阵，
    # 然而第五层全连接层需要的输入格式为向量，所以在这里需要将这个 7×7×64 的矩阵拉直成一
    # 个向量。pool2.get_shape 函数可以得到第四层输出矩阵的维度而不需要手工计算。注意
    # 因为每一层神经网络的输入输出都为 batch 的矩阵，所以这里得到的维度也包含了一个
    # batch 中数据的个数。
    pool_shape = pool2.get_shape().as_list()

```

```

# 计算将矩阵拉直成向量之后的长度，这个长度就是矩阵长宽及深度的乘积。注意这里
# pool_shape[0]为一个batch中数据的个数。
nodes = pool_shape[1] * pool_shape[2] * pool_shape[3]

# 通过tf.reshape函数将第四层的输出变成一个batch的向量。
reshaped = tf.reshape(pool2, [pool_shape[0], nodes])

# 声明第五层全连接层的变量并实现前向传播过程。这一层的输入是拉直之后的一组向量，
# 向量长度为3136，输出是一组长度为512的向量。这一层和之前在第5章中介绍的基本
# 一致，唯一的区别就是引入了dropout的概念。dropout在训练时会随机将部分节点的
# 输出改为0。dropout可以避免过拟合问题，从而使得模型在测试数据上的效果更好。
# dropout一般只在全连接层而不是卷积层或者池化层使用。
with tf.variable_scope('layer5-fc1'):
    fc1_weights = tf.get_variable(
        "weight", [nodes, FC_SIZE],
        initializer=tf.truncated_normal_initializer(stddev=0.1))
    # 只有全连接层的权重需要加入正则化。
    if regularizer != None:
        tf.add_to_collection('losses', regularizer(fc1_weights))
    fc1_biases = tf.get_variable(
        "bias", [FC_SIZE], initializer=tf.constant_initializer(0.1))

    fc1 = tf.nn.relu(tf.matmul(reshaped, fc1_weights) + fc1_biases)
    if train: fc1 = tf.nn.dropout(fc1, 0.5)

# 声明第六层全连接层的变量并实现前向传播过程。这一层的输入为一组长度为512的向量，
# 输出为一组长度为10的向量。这一层的输出通过Softmax之后就得到了最后的分类结果。
with tf.variable_scope('layer6-fc2'):
    fc2_weights = tf.get_variable(
        "weight", [FC_SIZE, NUM_LABELS],
        initializer=tf.truncated_normal_initializer(stddev=0.1))
    if regularizer != None:
        tf.add_to_collection('losses', regularizer(fc2_weights))
    fc2_biases = tf.get_variable(
        "bias", [NUM_LABELS],
        initializer=tf.constant_initializer(0.1))
    logit = tf.matmul(fc1, fc2_weights) + fc2_biases

# 返回第六层的输出。
return logit

```

运行修改后的 `mnist_train.py`，可以得到类似第5章中的输出：


```
~/mnist$ python mnist_train.py
Extracting /tmp/data/train-images-idx3-ubyte.gz
Extracting /tmp/data/train-labels-idx1-ubyte.gz
Extracting /tmp/data/t10k-images-idx3-ubyte.gz
Extracting /tmp/data/t10k-labels-idx1-ubyte.gz
After 1 training step(s), loss on training batch is 6.45373.
After 1001 training step(s), loss on training batch is 0.824825.
After 2001 training step(s), loss on training batch is 0.646993.
After 3001 training step(s), loss on training batch is 0.759975.
After 4001 training step(s), loss on training batch is 0.68468.
After 5001 training step(s), loss on training batch is 0.630368.
...
```

类似地修改第 5 章中给出的 `mnist_eval.py` 程序输入部分，就可以测试这个卷积神经网络在 MNIST 数据集上的正确率了。在 MNIST 测试数据上，上面给出的卷积神经网络可以达到大约 99.4% 的正确率。相比第 5 章中最高 98.4% 的正确率，卷积神经网络可以大幅提高神经网络在 MNIST 数据集上的正确率。

然而一种卷积神经网络架构不能解决所有问题。比如 LeNet-5 模型就无法很好地处理类似 ImageNet 这样比较大的图像数据集。那么如何设计卷积神经网络的架构呢？下面的正则表达式公式总结了一些经典的用于图片分类问题的卷积神经网络架构：

输入层→（卷积层+→池化层？）+→全连接层+

在上面的公式中，“卷积层+”表示一层或者多层卷积层，大部分卷积神经网络中一般最多连续使用三层卷积层。“池化层？”表示没有或者一层池化层。池化层虽然可以起到减少参数防止过拟合问题，但是在部分论文中也发现可以直接通过调整卷积层步长来完成^①。所以有些卷积神经网络中没有池化层。在多层卷积层和池化层之后，卷积神经网络在输出之前一般会经过 1~2 个全连接层。比如 LeNet-5 模型就可以表示为下面的结构。

输入层→卷积层→池化层→卷积层→池化层→全连接层→全连接层→输出层

除了 LeNet-5 模型，2012 年 ImageNet ILSVRC 图像分类挑战的第一名 AlexNet 模型、2013 年 ILSVRC 第一名 ZF Net 模型以及 2014 年第二名 VGGNet 模型的架构都满足上面介绍的正则表达式。表 6-1 给出了 VGGNet 论文 *Very Deep Convolutional Networks for Large-Scale Image Recognition*^② 中作者尝试过的不同卷积神经网络架构。从表 6-1 中可以看出这些卷积神经网络架构都满足介绍的正则表达式。

① 具体可以参考论文 *Striving for Simplicity: The All Convolutional Net*。

② Simonyan K, Zisserman A. *Very Deep Convolutional Networks for Large-Scale Image Recognition* [J]. Computer Science, 2014.

表 6-1 VGGNet 模型论文中尝试过的卷积神经网络架构^①

(其中 conv*表示卷积层, maxpool 表示池化层, FC-*表示全连接层, soft-max 为 softmax 结构)

input (224 × 224 RGB image)					
conv3-64	conv3-64 LRN	conv3-64 conv3-64	conv3-64	conv3-64	conv3-64
maxpool					
conv3-128	conv3-128	conv3-128 conv3-128	conv3-128	conv3-128	conv3-128
maxpool					
conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256 conv1-256	conv3-256 conv3-256 conv3-256	conv3-256 conv3-256 conv3-256 conv3-256
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
FC-4096					
FC-4096					
FC-1000					
soft-max					

有了卷积神经网络的架构,那么每一层卷积层或者池化层中的配置需要如何设置呢?表 6-1 也提供了很多线索。在表 6-1 中,convX-Y 表示过滤器的边长为 X,深度为 Y。比如 conv3-64 表示过滤器的长和宽都为 3,深度为 64。从表 6-1 中可以看出,VGG Net 中的过滤器边长一般为 3 或者 1。在 LeNet-5 模型中,也使用了边长为 5 的过滤器。一般卷积层的过滤器边长不会超过 5,但有些卷积神经网络结构中,处理输入的卷积层中使用了边长为 7 甚至是 11 的过滤器。

在过滤器的深度上,大部分卷积神经网络都采用逐层递增的方式。比如在表 6-1 中可以看到,每经过一次池化层之后,卷积层过滤器的深度会乘以 2。虽然不同的模型会选择使用不同的具体数字,但是逐层递增是比较普遍的模式。卷积层的步长一般为 1,但是在有些模型中也会使用 2,或者 3 作为步长。池化层的配置相对简单,用的最多的是最大池化层。池化层的过滤器边长一般为 2 或者 3,步长也一般为 2 或者 3。

6.4.2 Inception-v3 模型

在 6.4.1 小节中通过介绍 LeNet-5 模型整理出了一类经典的卷积神经网络架构设计。在这一小节中将介绍 Inception 结构以及 Inception-v3 卷积神经网络模型。Inception 结构是一

^① 此表源自论文 *Very Deep Convolutional Networks for Large-Scale Image Recognition*。

种和 LeNet-5 结构完全不同的卷积神经网络结构。在 LeNet-5 模型中，不同卷积层通过串联的方式连接在一起，而 Inception-v3 模型中的 Inception 结构是将不同的卷积层通过并联的方式结合在一起。在下面的篇幅中将具体介绍 Inception 结构，并通过 TensorFlow-Slim 工具来实现 Inception-v3 模型中的一个模块。

在 6.4.1 中提到了一个卷积层可以使用边长为 1、3 或者 5 的过滤器，那么如何在这些边长中选呢？Inception 模块给出了一个方案，那就是同时使用所有不同尺寸的过滤器，然后再将得到的矩阵拼接起来。图 6-16 给出了 Inception 模块的一个单元结构示意图。

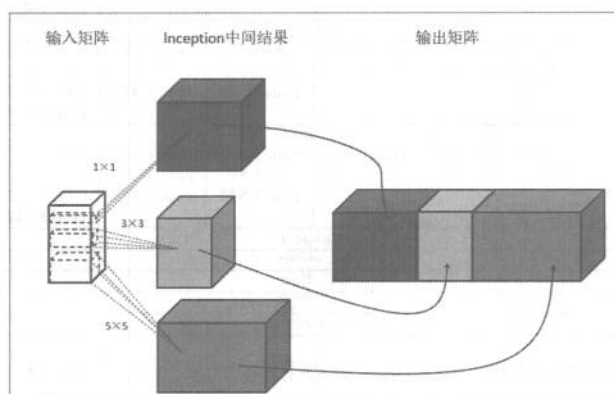


图 6-16 Inception 模块示意图。

从图 6-16 中可以看出，Inception 模块会首先使用不同尺寸的过滤器处理输入矩阵。在图 6-16 中，最上方矩阵为使用了边长为 1 的过滤器的卷积层前向传播的结果。类似的，中间矩阵使用的过滤器边长为 3，下方矩阵使用的过滤器边长为 5。不同的矩阵代表了 Inception 模块中的一条计算路径。虽然过滤器的大小不同，但如果所有的过滤器都使用全 0 填充且步长为 1，那么前向传播得到的结果矩阵的长和宽都与输入矩阵一致。这样经过不同过滤器处理的结果矩阵可以拼接成一个更深的矩阵。如图 6-16 所示，可以将它们在深度这个维度上组合起来。

图 6-16 所示的 Inception 模块得到的结果矩阵的长和宽与输入一样，深度为红黄蓝三个矩阵深度的和。图 6-16 中展示的是 Inception 模块的核心思想，真正在 Inception-v3 模型中使用的 Inception 模块要更加复杂且多样，有兴趣的读者可以参考论文 *Rethinking the Inception Architecture for Computer Vision*^①。图 6-17 给出了 Inception-v3 模型的架构图。

① Szegedy C, Vanhoucke V, Ioffe S, et al. Rethinking the Inception Architecture for Computer Vision[J]. Computer Science, 2015.




图 6-17 Inception-v3 模型架构图

Inception-v3 模型总共有 46 层，由 11 个 Inception 模块组成。图 6-17 中方框标注出来的结构就是一个 Inception 模块。在 Inception-v3 模型中有 96 个卷积层，如果将 6.4.1 小节中的程序直接搬过来，那么一个卷积层就需要 5 行代码，于是总共需要 480 行代码来实现所有的卷积层。这样使得代码的可读性非常差。为了更好地实现类似 Inception-v3 模型这样的复杂卷积神经网络，在下面将先介绍 TensorFlow-Slim 工具来更加简洁地实现一个卷积层。以下代码对比了直接使用 TensorFlow 实现一个卷积层和使用 TensorFlow-Slim 实现同样结构的神经网络的代码量。

```
# 直接使用 TensorFlow 原始 API 实现卷积层。
with tf.variable_scope(scope_name):
    weights = tf.get_variable("weight", ...)
    biases = tf.get_variable("bias", ...)
    conv = tf.nn.conv2d(...)
    relu = tf.nn.relu(tf.nn.bias_add(conv, biases))

# 使用 TensorFlow-Slim 实现卷积层。通过 TensorFlow-Slim 可以在一行中实现一个卷积层
# 的前向传播算法。slim.conv2d 函数的有 3 个参数是必填的。第一个参数为输入节点矩阵，第
# 二参数是当前卷积层过滤器的深度，第三个参数是过滤器的尺寸。可选的参数有过滤器移动的步
# 长、是否使用全 0 填充、激活函数的选择以及变量的命名空间等。
net = slim.conv2d(input, 32, [3, 3])
```

因为完整的 Inception-v3 模型比较长，所以在本书中仅提供 Inception-v3 模型中结构相对复杂的一个 Inception 模块的代码实现^①。以下代码实现了图 6-17 中红色方框中的 Inception 模块。

① 在 TensorFlow 的 GitHub 代码库上找到完整的 Inception-v3 模型的源码。GitHub 的地址为 https://github.com/tensorflow/tensorflow/blob/master/tensorflow/contrib/slim/python/slim/nets/inception_v3.py。

```

# slim.arg_scope 函数可以用于设置默认的参数取值。slim.arg_scope 函数的第一个参数是
# 一个函数列表，在这个列表中的函数将使用默认的参数取值。比如通过下面的定义，调用
# slim.conv2d(net, 320, [1, 1])函数时会自动加上 stride=1 和 padding='SAME'的参数。如果在函数调用时指定了 stride，那么这里设置的默认值就不会再使用。通过这种方式
# 可以进一步减少冗余的代码。
with slim.arg_scope([slim.conv2d, slim.max_pool2d, slim.avg_pool2d],
                    stride=1, padding='SAME'):

    ...
    # 此处省略了 Inception-v3 模型中其他的网络结构而直接实现最后面红色方框中的。
    # Inception 结构。假设输入图片经过之前的神经网络前向传播的结果保存在变量 net
    # 中。
    net = 上一层的输出节点矩阵
    # 为一个 Inception 模块声明一个统一的变量命名空间。
    with tf.variable_scope('Mixed_7c'):
        # 给 Inception 模块中每一条路径声明一个命名空间。
        with tf.variable_scope('Branch_0'):
            # 实现一个过滤器边长为 1，深度为 320 的卷积层。
            branch_0 = slim.conv2d(net, 320, [1, 1], scope='Conv2d_0a_1x1')

        # Inception 模块中第二条路径。这条计算路径上的结构本身也是一个 Inception 结
        # 构。
        with tf.variable_scope('Branch_1'):
            branch_1 = slim.conv2d(net, 384, [1, 1], scope='Conv2d_0a_1x1')
            # tf.concat 函数可以将多个矩阵拼接起来。tf.concat 函数的第一个参数指定
            # 了拼接的维度，这里给出的“3”代表了矩阵是在深度这个维度上进行拼接。图 6-16
            # 中展示了在深度上拼接矩阵的方式。
            branch_1 = tf.concat(3, [
                # 如图 6-17 所示，此处 2 层卷积层的输入都是 branch_1 而不是 net。
                slim.conv2d(branch_1, 384, [1, 3], scope='Conv2d_0b_1x3'),
                slim.conv2d(branch_1, 384, [3, 1], scope='Conv2d_0c_3x1')])

        # Inception 模块中第三条路径。此计算路径也是一个 Inception 结构。
        with tf.variable_scope('Branch_2'):
            branch_2 = slim.conv2d(
                net, 448, [1, 1], scope='Conv2d_0a_1x1')
            branch_2 = slim.conv2d(
                branch_2, 384, [3, 3], scope='Conv2d_0b_3x3')
            branch_2 = tf.concat(3, [
                slim.conv2d(branch_2, 384,
                    [1, 3], scope='Conv2d_0c_1x3'),
                slim.conv2d(branch_2, 384,
                    [3, 1], scope='Conv2d_0d_3x1')])

```

```

# Inception 模块中第四条路径。
with tf.variable_scope('Branch_3'):
    branch_3 = slim.avg_pool2d(
        net, [3, 3], scope='AvgPool_0a_3x3')
    branch_3 = slim.conv2d(
        branch_3, 192, [1, 1], scope='Conv2d_0b_1x1')

# 当前 Inception 模块的最后输出是由上面四个计算结果拼接得到的。
net = tf.concat(3, [branch_0, branch_1, branch_2, branch_3])

```

6.5 卷积神经网络迁移学习

在本节中将介绍迁移学习的概念以及如何通过 TensorFlow 来实现迁移学习。在 6.5.1 小节中将讲解迁移学习的动机，并介绍如何将一个数据集上训练好的卷积神经网络模型快速转移到另外一个数据集上。在 6.5.2 小节中将给出一个具体的 TensorFlow 程序将 ImageNet 上训练好的 Inception-v3 模型转移到另外一个图像分类数据集上。

6.5.1 迁移学习介绍

在 6.4 节中介绍了 1998 年提出的 LeNet-5 模型和 2015 年提出的 Inception-v3 模型。对比这两个模型可以发现，卷积神经网络模型的层数和复杂度都发生了巨大的变化。表 6-2 给出了从 2012 年到 2015 年 ILSVRC (Large Scale Visual Recognition Challenge) 第一名模型的层数以及前五个答案的错误率。

表 6-2 ILSVRC 第一名模型信息列表

年份	模型名称	层数 ^①	Top5 错误率
2012	AlexNet	8	15.3%
2013	ZF Net	8	14.8%
2014	GoogLeNet	22	6.67%
2015	ResNet	152	3.57%

从表 6-2 可以看到，随着模型层数及复杂度的增加，模型在 ImageNet 上的错误率也随之降低。然而，训练复杂的卷积神经网络需要非常多的标注数据。如 6.1 节中提到的，

① 在这里层数只计算了卷积层和全连接层的个数，没有参数的池化层没有包括在内。

ImageNet 图像分类数据集中有 120 万标注图片,所以才能将 152 层的 ResNet 的模型训练到大约 96.5%的正确率。在真实的应用中,很难收集到如此多的标注数据。即使可以收集到,也需要花费大量人力物力。而且即使有海量的训练数据,要训练一个复杂的卷积神经网络也需要几天甚至几周的时间。为了解决标注数据和训练时间的问题,可以使用本节将要介绍的迁移学习。

所谓迁移学习,就是将一个问题上训练好的模型通过简单的调整使其适用于一个新的问题。本小节将介绍如何利用 ImageNet 数据集上训练好的 Inception-v3 模型来解决一个新的图像分类问题。根据论文 *DeCAF: A Deep Convolutional Activation Feature for Generic Visual Recognition*^①中的结论,可以保留训练好的 Inception-v3 模型中所有卷积层的参数,只是替换最后一层全连接层。在最后这一层全连接层之前的网络层称之为瓶颈层(bottleneck)。

将新的图像通过训练好的卷积神经网络直到瓶颈层的过程可以看成是对图像进行特征提取的过程。在训练好的 Inception-v3 模型中,因为将瓶颈层的输出再通过一个单层的全连接层神经网络可以很好地区分 1000 种类别的图像,所以有理由认为瓶颈层输出的节点向量可以被作为任何图像的一个更加精简且表达能力更强的特征向量。于是,在新数据集上,可以直接利用这个训练好的神经网络对图像进行特征提取,然后再将提取得到的特征向量作为输入来训练一个新的单层全连接神经网络处理新的分类问题。

一般来说,在数据量足够的情况下,迁移学习的效果不如完全重新训练。但是迁移学习所需要的训练时间和训练样本数要远远小于训练完整的模型。在没有 GPU^②的普通台式机或者笔记本电脑上,6.5.2 小节中给出的 TensorFlow 训练过程只需要大约 5 分钟^③,而且可以达到大概 90%的正确率。

6.5.2 TensorFlow 实现迁移学习

本小节将给出一个完整的 TensorFlow 程序来介绍如何通过 TensorFlow 实现迁移学习。以下代码给出了如何下载这一小节中将要用到的数据集。

```
curl http://download.tensorflow.org/example_images/flower_photos.tgz
tar xzf flower_photos.tgz
```

① Donahue J, Jia Y, Vinyals O, et al. *DeCAF: A Deep Convolutional Activation Feature for Generic Visual Recognition* [J]. Computer Science, 2013.

② 第 10 章将介绍 TensorFlow 如何使用 GPU 加速训练过程。

③ 数据下载和数据预处理的时间没有计算在内。

解压之后的文件夹包含了 5 个子文件夹，每一个子文件夹的名称为一种花的名称，代表了不同的类别。平均每一种花有 734 张图片，每一张图片都是 RGB 色彩模式的，大小也不相同。和之前的样例不同，在这一小节中给出的程序将直接处理没有整理过的图像数据。同时，通过下面的命名可以下载谷歌提供的训练好的 Inception-v3 模型。

```
wget https://storage.googleapis.com/download.tensorflow.org/models/\
inception_dec_2015.zip
unzip tensorflow/examples/label_image/data/inception_dec_2015.zip
```

当新的数据集和已经训练好的模型都准备好之后，可以通过以下代码来完成迁移学习的过程。

```
# -*- coding: utf-8 -*-

import glob
import os.path
import random
import numpy as np
import tensorflow as tf
from tensorflow.python.platform import gfile

# Inception-v3 模型瓶颈层的节点个数。
BOTTLENECK_TENSOR_SIZE = 2048

# Inception-v3 模型中代表瓶颈层结果的张量名称。在谷歌提供的 Inception-v3 模型中，这
# 个张量名称就是 'pool_3/_reshape:0'。在训练的模型时，可以通过 tensor.name 来获取张
# 量的名称。
BOTTLENECK_TENSOR_NAME = 'pool_3/_reshape:0'

# 图像输入张量所对应的名称。
JPEG_DATA_TENSOR_NAME = 'DecodeJpeg/contents:0'

# 下载的谷歌训练好的 Inception-v3 模型文件目录。
MODEL_DIR = '/path/to/model'

# 下载的谷歌训练好的 Inception-v3 模型文件名。
MODEL_FILE = 'classify_image_graph_def.pb'

# 因为一个训练数据会被使用多次，所以可以将原始图像通过 Inception-v3 模型计算得到
# 的特征向量保存在文件中，免去重复的计算。下面的变量定义了这些文件的存放地址。
CACHE_DIR = '/tmp/bottleneck'

# 图片数据文件夹。在这个文件夹中每一个子文件夹代表一个需要区分的类别，每个子文件夹中
# 存放了对应类别的图片。
```

```

INPUT_DATA = '/path/to/flower_data'

# 验证的数据百分比。
VALIDATION_PERCENTAGE = 10
# 测试的数据百分比。
TEST_PERCENTAGE = 10

# 定义神经网络的设置。
LEARNING_RATE = 0.01
STEPS = 4000
BATCH = 100

# 这个函数从数据文件夹中读取所有的图片列表并按训练、验证、测试数据分开。
# testing_percentage 和 validation_percentage 参数指定了测试数据集和验证数据集的
# 大小。
def create_image_lists(testing_percentage, validation_percentage):
    # 得到的所有图片都存在 result 这个字典 (dictionary) 里。这个字典的 key 为类别的名
    # 称, value 是也是一个字典, 字典里存储了所有的图片名称。
    result = {}
    # 获取当前目录下所有的子目录。
    sub_dirs = [x[0] for x in os.walk(INPUT_DATA)]
    # 得到的第一个目录是当前目录, 不需要考虑。
    is_root_dir = True
    for sub_dir in sub_dirs:
        if is_root_dir:
            is_root_dir = False
            continue

        # 获取当前目录下所有有效图片文件。
        extensions = ['jpg', 'jpeg', 'JPG', 'JPEG']
        file_list = []
        dir_name = os.path.basename(sub_dir)
        for extension in extensions:
            file_glob = os.path.join(INPUT_DATA, dir_name, '*' + extension)
            file_list.extend(glob.glob(file_glob))
        if not file_list: continue

        # 通过目录名获取类别的名称。
        label_name = dir_name.lower()
        # 初始化当前类别的训练数据集、测试数据集和验证数据集。
        training_images = []
        testing_images = []
        validation_images = []
        for file_name in file_list:
            base_name = os.path.basename(file_name)
            # 随机将数据分到训练数据集、测试数据集和验证数据集。

```

```

        chance = np.random.randint(100)
        if chance < validation_percentage:
            validation_images.append(base_name)
        elif chance < (testing_percentage + validation_percentage):
            testing_images.append(base_name)
        else:
            training_images.append(base_name)

    # 将当前类别的数据放入结果字典。
    result[label_name] = {
        'dir': dir_name,
        'training': training_images,
        'testing': testing_images,
        'validation': validation_images,
    }
# 返回整理好的所有数据。
return result

# 这个函数通过类别名称、所属数据集和图片编号获取一张图片的地址。
# image_lists 参数给出了所有图片信息。
# image_dir 参数给出了根目录。存放图片数据的根目录和存放图片特征向量的根目录地址不同。
# label_name 参数给定了类别的名称。
# index 参数给定了需要获取的图片的编号。
# category 参数指定了需要获取的图片是在训练数据集、测试数据集还是验证数据集。
def get_image_path(image_lists, image_dir, label_name, index, category):
    # 获取给定类别中所有图片的信息。
    label_lists = image_lists[label_name]
    # 根据所属数据集的名称获取集合中的全部图片信息。
    category_list = label_lists[category]
    mod_index = index % len(category_list)
    # 获取图片的文件名。
    base_name = category_list[mod_index]
    sub_dir = label_lists['dir']
    # 最终的地址为数据根目录的地址加上类别的文件夹加上图片的名称。
    full_path = os.path.join(image_dir, sub_dir, base_name)
    return full_path

# 这个函数通过类别名称、所属数据集和图片编号获取经过 Inception-v3 模型处理之后的特征向量
# 文件地址。
def get_bottleneck_path(image_lists, label_name, index, category):
    return get_image_path(image_lists, CACHE_DIR,
                          label_name, index, category) + '.txt'

# 这个函数使用加载的训练好的 Inception-v3 模型处理一张图片，得到这个图片的特征向量。
def run_bottleneck_on_image(sess, image_data, image_data_tensor,
                           bottleneck_tensor):

```

```

# 这个过程实际上就是将当前图片作为输入计算瓶颈张量的值。这个瓶颈张量的值就是这
# 张图片的新的特征向量。
bottleneck_values = sess.run(bottleneck_tensor,
                             {image_data_tensor: image_data})
# 经过卷积神经网络处理的结果是一个四维数组，需要将这个结果压缩成一个特征
# 向量（一维数组）。
bottleneck_values = np.squeeze(bottleneck_values)
return bottleneck_values

# 这个函数获取一张图片经过 Inception-v3 模型处理之后的特征向量。这个函数会先试图寻找
# 已经计算且保存下来的特征向量，如果找不到则先计算这个特征向量，然后保存到文件。
def get_or_create_bottleneck(
    sess, image_lists, label_name, index,
    category, jpeg_data_tensor, bottleneck_tensor):
    # 获取一张图片对应的特征向量文件的路径。
    label_lists = image_lists[label_name]
    sub_dir = label_lists['dir']
    sub_dir_path = os.path.join(CACHE_DIR, sub_dir)
    if not os.path.exists(sub_dir_path): os.makedirs(sub_dir_path)
    bottleneck_path = get_bottleneck_path(
        image_lists, label_name, index, category)

    # 如果这个特征向量文件不存在，则通过 Inception-v3 模型来计算特征向量，并将计算的结果
    # 存入文件。
    if not os.path.exists(bottleneck_path):
        # 获取原始的图片路径。
        image_path = get_image_path(
            image_lists, INPUT_DATA, label_name, index, category)
        # 获取图片内容。
        image_data = gfile.FastGFile(image_path, 'rb').read()
        # 通过 Inception-v3 模型计算特征向量。
        bottleneck_values = run_bottleneck_on_image(
            sess, image_data, jpeg_data_tensor, bottleneck_tensor)
        # 将计算得到的特征向量存入文件。
        bottleneck_string = ','.join(str(x) for x in bottleneck_values)
        with open(bottleneck_path, 'w') as bottleneck_file:
            bottleneck_file.write(bottleneck_string)
    else:
        # 直接从文件中获取图片相应的特征向量。
        with open(bottleneck_path, 'r') as bottleneck_file:
            bottleneck_string = bottleneck_file.read()
            bottleneck_values = [float(x) for x in bottleneck_string.split(',')]
    # 返回得到的特征向量。
    return bottleneck_values

# 这个函数随机获取一个 batch 的图片作为训练数据。

```



```

def get_random_cached_bottlenecks(
    sess, n_classes, image_lists, how_many, category,
    jpeg_data_tensor, bottleneck_tensor):
    bottlenecks = []
    ground_truths = []
    for _ in range(how_many):
        # 随机一个类别和图片的编号加入当前的训练数据。
        label_index = random.randrange(n_classes)
        label_name = list(image_lists.keys())[label_index]
        image_index = random.randrange(65536)
        bottleneck = get_or_create_bottleneck(
            sess, image_lists, label_name, image_index, category,
            jpeg_data_tensor, bottleneck_tensor)
        ground_truth = np.zeros(n_classes, dtype=np.float32)
        ground_truth[label_index] = 1.0
        bottlenecks.append(bottleneck)
        ground_truths.append(ground_truth)

    return bottlenecks, ground_truths

# 这个函数获取全部的测试数据。在最终测试的时候需要在所有的测试数据上计算正确率。
def get_test_bottlenecks(sess, image_lists, n_classes,
    jpeg_data_tensor, bottleneck_tensor):

    bottlenecks = []
    ground_truths = []
    label_name_list = list(image_lists.keys())
    # 枚举所有的类别和每个类别中的测试图片。
    for label_index, label_name in enumerate(label_name_list):
        category = 'testing'
        for index, unused_base_name in enumerate(
            image_lists[label_name][category]):
            # 通过 Inception-v3 模型计算图片对应的特征向量,并将其加入最终数据的列表。
            bottleneck = get_or_create_bottleneck(
                sess, image_lists, label_name, index, category,
                jpeg_data_tensor, bottleneck_tensor)
            ground_truth = np.zeros(n_classes, dtype=np.float32)
            ground_truth[label_index] = 1.0
            bottlenecks.append(bottleneck)
            ground_truths.append(ground_truth)
    return bottlenecks, ground_truths

def main(_):
    # 读取所有图片。
    image_lists = create_image_lists(TEST_PERCENTAGE, VALIDATION_PERCENTAGE)
    n_classes = len(image_lists.keys())

```



```

# 读取已经训练好的 Inception-v3 模型。谷歌训练好的模型保存在了 GraphDef Protocol
# Buffer 中，里面保存了每一个节点取值的计算方法以及变脸的取值。TensorFlow 模型持
# 久化的问题在第 5 章中有详细的介绍。
with gfile.GFile(os.path.join(MODEL_DIR, MODEL_FILE), 'rb') as f:
    graph_def = tf.GraphDef()
    graph_def.ParseFromString(f.read())
# 加载读取的 Inception-v3 模型，并返回数据输入所对应的张量以及计算瓶颈层结果所对应
# 的张量。
bottleneck_tensor, jpeg_data_tensor = tf.import_graph_def(
    graph_def,
    return_elements=[BOTTLENECK_TENSOR_NAME, JPEG_DATA_TENSOR_NAME])

# 定义新的神经网络输入，这个输入就是新的图片经过 Inception-v3 模型前向传播到达瓶颈层
# 是的节点取值。可以将这个过程类似的理解为一种特征提取。
bottleneck_input = tf.placeholder(
    tf.float32, [None, BOTTLENECK_TENSOR_SIZE],
    name='BottleneckInputPlaceholder')
# 定义新的标准答案输入。
ground_truth_input = tf.placeholder(
    tf.float32, [None, n_classes], name='GroundTruthInput')
# 定义一层全链接层来解决新的图片分类问题。因为训练好的 Inception-v3 模型已经将原始
# 的图片抽象为了更加容易分类的特征向量了，所以不需要再训练那么复杂的神经网络来完成
# 这个新的分类任务。
with tf.name_scope('final_training_ops'):
    weights = tf.Variable(tf.truncated_normal(
        [BOTTLENECK_TENSOR_SIZE, n_classes], stddev=0.001))
    biases = tf.Variable(tf.zeros([n_classes]))
    logits = tf.matmul(bottleneck_input, weights) + biases
    final_tensor = tf.nn.softmax(logits)

# 定义交叉熵损失函数。
cross_entropy = tf.nn.softmax_cross_entropy_with_logits(
    logits, ground_truth_input)
cross_entropy_mean = tf.reduce_mean(cross_entropy)
train_step = tf.train.GradientDescentOptimizer(LEARNING_RATE)\
    .minimize(cross_entropy_mean)

# 计算正确率。
with tf.name_scope('evaluation'):
    correct_prediction = tf.equal(tf.argmax(final_tensor, 1),
        tf.argmax(ground_truth_input, 1))
    evaluation_step = tf.reduce_mean(
        tf.cast(correct_prediction, tf.float32))

with tf.Session() as sess:
    init = tf.initialize_all_variables()

```

```

sess.run(init)

# 训练过程。
for i in range(STEPS):
    # 每次获取一个 batch 的训练数据。
    train_bottlenecks, train_ground_truth = \
        get_random_cached_bottlenecks(
            sess, n_classes, image_lists, BATCH,
            'training', jpeg_data_tensor, bottleneck_tensor)
    sess.run(train_step,
              feed_dict={bottleneck_input: train_bottlenecks,
                          ground_truth_input: train_ground_truth})

    # 在验证数据上测试正确率。
    if i % 100 == 0 or i + 1 == STEPS:
        validation_bottlenecks, validation_ground_truth = \
            get_random_cached_bottlenecks(
                sess, n_classes, image_lists, BATCH,
                'validation', jpeg_data_tensor, bottleneck_tensor)
        validation_accuracy = sess.run(
            evaluation_step, feed_dict={
                bottleneck_input: validation_bottlenecks,
                ground_truth_input: validation_ground_truth})
        print('Step %d: Validation accuracy on random sampled '
              '%d examples = %.1f%%' %
              (i, BATCH, validation_accuracy * 100))

    # 在最后的测试数据上测试正确率。
    test_bottlenecks, test_ground_truth = get_test_bottlenecks(
        sess, image_lists, n_classes, jpeg_data_tensor,
        bottleneck_tensor)
    test_accuracy = sess.run(evaluation_step, feed_dict={
        bottleneck_input: test_bottlenecks,
        ground_truth_input: test_ground_truth})
    print('Final test accuracy = %.1f%%' % (test_accuracy * 100))

if __name__ == '__main__':
    tf.app.run()

```

运行上面的程序将需要大约 40 分钟（数据处理 35 分钟，训练 5 分钟），可以得到类似下面的结果：

```

Step 0: Validation accuracy on random sampled 100 examples = 44.0%
Step 200: Validation accuracy on random sampled 100 examples = 79.0%
Step 400: Validation accuracy on random sampled 100 examples = 85.0%
Step 600: Validation accuracy on random sampled 100 examples = 92.0%

```

```
Step 800: Validation accuracy on random sampled 100 examples = 87.0%
Step 1000: Validation accuracy on random sampled 100 examples = 93.0%
...
Step 3999: Validation accuracy on random sampled 100 examples = 94.0%
Final test accuracy = 93.6%
```

从上面的结果可以看到，模型在新的数据集上很快能够收敛，并达到还不错的分类效果。

小结

在本章中详细介绍了如何通过卷积神经网络解决图像识别问题。首先，在 6.1 节中讲解了什么是图像识别问题，并介绍了图像识别问题中的一些经典公开数据集。在这一节中介绍了不同算法在这些公开数据集上的表现，并指出卷积神经网络给这个领域带来了质的飞越。接着，在 6.2 节中介绍了卷积神经网络的基本思想。在这一节中指出了全连接神经网络在处理图像数据上的不足之处，并给出了经典的卷积神经网络中包含的不同网络结构。

在 6.3 节中详细讲述了卷积神经网络中比较重要的两个网络结构——卷积层和池化层。本节详细介绍了这两种网络结构的前向传播算法，并给出了 TensorFlow 中的代码实现。在 6.4 节中，通过两种经典的卷积神经网络模型介绍了如何设计一个卷积神经网络的架构，并介绍了配置卷积层和池化层中设置的一些经验。在这一节中给出了一个完成的 TensorFlow 程序来实现 LeNet-5 模型，通过这个模型可以将 MNIST 数据集上的正确率进一步提升到大约 99.4%。这一节中还简单介绍了 TensorFlow-Slim 工具，通过这个工具可以巨幅提高实现复杂神经网络的编程效率。最后在 6.5 节中，介绍了迁移学习的概念并给出了一个完整的 TensorFlow 来实现迁移学习。通过迁移学习，可以使用少量训练数据在短时间内训练出效果还不错的神经网络模型。

在这一章中，通过图像识别问题介绍了卷积神经网络。通过这种特殊结构的神经网络，可以将图像识别问题的准确率提高到一个新的层次。除了改进模型，TensorFlow 还提供了很多图像处理的函数以方便图像处理。在第 7 章中将具体介绍这些函数。同时也将介绍如何使用 TensorFlow 更好地处理输入数据。

第 7 章 图像数据处理

在第 6 章中详细介绍了卷积神经网络，并提到通过卷积神经网络给图像识别技术带来了突破性进展。这一章将从另外一个维度来进一步提升图像识别的精度以及训练的速度。喜欢摄影的读者都知道图像的亮度、对比度等属性对图像的影响是非常大的，相同物体在不同亮度、对比度下差别非常大。然而在很多图像识别问题中，这些因素都不应该影响最后的识别结果。所以本章将介绍如何对图像数据进行预处理使训练得到的神经网络模型尽可能小地被无关因素所影响。但与此同时，复杂的预处理过程可能导致训练效率的下降。为了减小预处理对于训练速度的影响，在本章中也将详细地介绍 TensorFlow 中多线程处理输入数据的解决方案。

本章将根据数据预处理的先后顺序来组织不同的小节。首先在 7.1 节中将介绍如何统一输入数据的格式，使得在之后系统中可以更加方便地处理。来自实际问题的数据往往有很多格式和属性，这一节将介绍的 TFRecord 格式可以统一不同的原始数据格式，并更加有效地管理不同的属性。接着在 7.2 节中将介绍如何对图像数据进行预处理。这一节将列举 TensorFlow 支持的图像处理函数，并介绍如何使用这些处理方式来弱化与图像识别无关的因素。复杂的图像处理函数有可能降低训练的速度，为了加速数据预处理过程，7.3 节将完整地介绍 TensorFlow 多线程数据预处理流程。在这一节中将首先介绍 TensorFlow 中多线程和队列的概念，这是 TensorFlow 多线程数据预处理的基本组成部分。然后将具体介绍数据预处理流程中的每个部分。在本节的最后将给出一个完整的多线程数据预处理流程图和程序框架。

7.1 TFRecord 输入数据格式

TensorFlow 提供了一种统一的格式来存储数据，这个格式就是 TFRecord。6.5 节给出了一个程序来处理花朵分类的数据。在这个程序中，使用了一个从类别名称到所有数据列

表的词典来维护图像和类别的关系。这种方式的可扩展性非常差，当数据来源更加复杂、每一个样例中的信息更加丰富之后，这种方式就很难有效地记录输入数据中的信息了。于是 TensorFlow 提供了 TFRecord 的格式来统一存储数据。这一节将介绍如何使用 TFRecord 来统一输入数据的格式。

7.1.1 TFRecord 格式介绍

TFRecord 文件中的数据都是通过 `tf.train.Example Protocol Buffer` 的格式存储的。以下代码给出了 `tf.train.Example` 的定义。

```
message Example {
  Features features = 1;
};

message Features {
  map<string, Feature> feature = 1;
};

message Feature {
  oneof kind {
    BytesList bytes_list = 1;
    FloatList float_list = 2;
    Int64List int64_list = 3;
  }
};
```

从以上代码可以看出 `tf.train.Example` 的数据结构是比较简洁的。`tf.train.Example` 中包含了一个从属性名称到取值的字典。其中属性名称为一个字符串，属性的取值可以为字符串 (`BytesList`)，实数列表 (`FloatList`) 或者整数列表 (`Int64List`)。比如将一张解码前的图像存为一个字符串，图像所对应的类别编号存为整数列表。在 7.1.2 小节中将给出一个使用 TFRecord 的具体样例。

7.1.2 TFRecord 样例程序

本小节将给出具体的样例程序来读写 TFRecord 文件。下面的程序给出了如何将 MNIST 输入数据转化为 TFRecord 的格式。

```
import tensorflow as tf
from tensorflow.examples.tutorials.mnist import input_data
```

```

import numpy as np

# 生成整数型的属性。
def _int64_feature(value):
    return tf.train.Feature(int64_list=tf.train.Int64List(value=[value]))

# 生成字符串型的属性。
def _bytes_feature(value):
    return tf.train.Feature(bytes_list=tf.train.BytesList(value=[value]))

mnist = input_data.read_data_sets(
    "/path/to/mnist/data", dtype=tf.uint8, one_hot=True)
images = mnist.train.images
# 训练数据所对应的正确答案，可以作为一个属性保存在 TFRecord 中。
labels = mnist.train.labels
# 训练数据的图像分辨率，这可以作为 Example 中的一个属性。
pixels = images.shape[1]
num_examples = mnist.train.num_examples

# 输出 TFRecord 文件的地址。
filename = "/path/to/output.tfrecords"
# 创建一个 writer 来写 TFRecord 文件。
writer = tf.python_io.TFRecordWriter(filename)
for index in range(num_examples):
    # 将图像矩阵转化成一个字符串。
    image_raw = images[index].tostring()
    # 将一个样例转化为 Example Protocol Buffer，并将所有的信息写入这个数据结构。
    example = tf.train.Example(features=tf.train.Features(feature={
        'pixels': _int64_feature(pixels),
        'label': _int64_feature(np.argmax(labels[index])),
        'image_raw': _bytes_feature(image_raw)}))

    # 将一个 Example 写入 TFRecord 文件。
    writer.write(example.SerializeToString())
writer.close()

```

以上程序可以将 MNIST 数据集中所有的训练数据存储到一个 TFRecord 文件中。当数据量较大时，也可以将数据写入多个 TFRecord 文件。TensorFlow 对从文件列表中读取数据提供了很好的支持，在 7.3.2 小节中将详细介绍。以下程序给出了如何读取 TFRecord 文件中的数据。


```
import tensorflow as tf

# 创建一个 reader 来读取 TFRecord 文件中的样例。
reader = tf.TFRecordReader()
# 创建一个队列来维护输入文件列表，在 7.3.2 小节中将更加详细的介绍
# tf.train.string_input_producer 函数。
filename_queue = tf.train.string_input_producer(
    ["/path/to/output.tfrecords"])

# 从文件中读出一个样例。也可以使用 read_up_to 函数一次性读取多个样例。
_, serialized_example = reader.read(filename_queue)
# 解析读入的一个样例。如果需要解析多个样例，可以用 parse_example 函数。
features = tf.parse_single_example(
    serialized_example,
    features={
        # TensorFlow 提供两种不同的属性解析方法。一种是方法是 tf.FixedLenFeature,
        # 这种方法解析的结果为一个 Tensor。另一种方法是 tf.VarLenFeature, 这种方法
        # 得到的解析结果为 SparseTensor, 用于处理稀疏数据。这里解析数据的格式需要和
        # 上面程序写入数据的格式一致。
        'image_raw': tf.FixedLenFeature([], tf.string),
        'pixels': tf.FixedLenFeature([], tf.int64),
        'label': tf.FixedLenFeature([], tf.int64),
    })

# tf.decode_raw 可以将字符串解析成图像对应的像素数组。
images = tf.decode_raw(features['image_raw'], tf.uint8)
labels = tf.cast(features['label'], tf.int32)
pixels = tf.cast(features['pixels'], tf.int32)

sess = tf.Session()
# 启动多线程处理输入数据，7.3 节将更加详细地介绍 TensorFlow 多线程处理。
coord = tf.train.Coordinator()
threads = tf.train.start_queue_runners(sess=sess, coord=coord)

# 每次运行可以读取 TFRecord 文件中的一个样例。当所有样例都读完之后，在此样例中程序
# 会在重头读取。
for i in range(10):
    image, label, pixel = sess.run([images, labels, pixels])
```

7.2 图像数据处理

在之前的几章中多次使用到了图像识别数据集。然而在之前的章节中都是直接使用图

像原始的像素矩阵。这一节将介绍图像的预处理过程。通过对图像的预处理，可以尽量避免模型受到无关因素的影响。在大部分图像识别问题中，通过图像预处理过程可以提高模型的准确率。在 7.2.1 小节中将先介绍 TensorFlow 提供的主要图像处理函数，并给出具体图像在处理前和处理后的变化让读者有一个直观的了解。然后在 7.2.2 小节中将给出一个完整的图像预处理流程。

7.2.1 TensorFlow 图像处理函数

TensorFlow 提供了几类图像处理函数，在本小节中将一一介绍这些图像处理函数。

图像编码处理

在之前的章节中提到一张 RGB 色彩模式的图像可以看成是一个三维矩阵，矩阵中的每一个数表示了图像上不同位置，不同颜色的亮度。然而图像在存储时并不是直接记录这些矩阵中的数字，而是记录经过压缩编码之后的结果。所以要将一张图像还原成一个三维矩阵，需要解码的过程。TensorFlow 提供了对 jpeg 和 png 格式图像的编码/解码函数。以下代码示范了如何使用 TensorFlow 中对 jpeg 格式图像的编码/解码函数。

```
# matplotlib.pyplot 是一个 python 的画图工具①。在这一节中将使用这个工具来可视
# 化经过 TensorFlow 处理的图像。
import matplotlib.pyplot as plt
import tensorflow as tf

# 读取图像的原始数据。
image_raw_data = tf.gfile.FastGFile("/path/to/picture", 'r').read()

with tf.Session() as sess:
    # 将图像使用 jpeg 的格式解码从而得到图像对应的三维矩阵。TensorFlow 还提供了
    # tf.image.decode_png 函数对 png 格式的图像进行解码。解码之后的结果为一个
    # 张量，在使用它的取值之前需要明确调用运行的过程。
    img_data = tf.image.decode_jpeg(image_raw_data)

    print img_data.eval()
    # 输出解码之后的三维矩阵，上面这一行将输出下面的内容。
    '''
    [[[165 160 138]
      ...
      [105 140 50]]
```

① 关于 pyplot 更加详细的介绍可以参考 <http://matplotlib.org/index.html>

```

[[166 161 139]
 ...,
[106 139  48]]

...,

[[207 200 181]
 ...,
[106  81  50]]]
'''

# 使用 pyplot 工具可视化得到的图像。可以得到图 7-1 中展示了的图像。
plt.imshow(img_data.eval())
plt.show()

# 将数据的类型转化成实数方便下面的样例程序对图像进行处理。
img_data = tf.image.convert_image_dtype(img_data, dtype=tf.float32)

# 将表示一张图像的三维矩阵重新按照 jpeg 格式编码并存入文件中。打开这张图像，
# 可以得到和原始图像一样的图像。
encoded_image = tf.image.encode_jpeg(img_data)
with tf.gfile.GFile("/path/to/output", "wb") as f:
    f.write(encoded_image.eval())

```

图 7-1 显示了上面代码可视化出来的一张图像，在下面的篇幅中将继续使用这张图像来介绍 TensorFlow 其他图像处理的函数。




图 7-1 本节样例代码中使用到的原始图像^①

图像大小调整

一般来说，网络上获取的图像大小是不固定，但神经网络输入节点的个数是固定的。

^① 原始图像是彩色的，在 GitHub 代码库里有原始图像。

所以在将图像的像素作为输入提供给神经网络之前，需要先将图像的大小统一。这就是图像大小调整需要完成的任务。图像大小调整有两种方式，第一种是通过算法使得新的图像尽量保存原始图像上的所有信息。TensorFlow 提供了四种不同的方法，并且将它们封装到了 `tf.image.resize_images` 函数。以下代码示范了如何使用这个函数。

```
# 加载原始图像，定义会话等过程和图像编码处理中代码一致，在下面的样例中就全部略去了，
# 假设 img_data 是已经解码且进行过类型转化的图像。
...

# 通过 tf.image.resize_images 函数调整图像的大小。这个函数第一个参数为原始图像，
# 第二个和第三个参数为调整后图像的大小，method 参数给出了调整图像大小的算法。
resized = tf.image.resize_images(img_data, 300, 300, method=0)


# 输出调整后图像的大小，此处的结果为 (300, 300, ?)。表示图像的大小是 300×300，
# 但图像的深度在没有明确设置之前会是问号。
print img_data.get_shape()

# 通过 pyplot 可视化的过程和图像编码处理中给出的代码一致，在以下代码中也将略去。
```

表 7-1 给出了 `tf.image.resize_images` 函数的 `method` 参数取值对应的图像大小调整算法。图 7-2 对比了不同大小调整算法得到的结果。

表 7-1 `tf.image.resize_images` 函数中 `method` 参数取值与相对应的图像大小调整算法

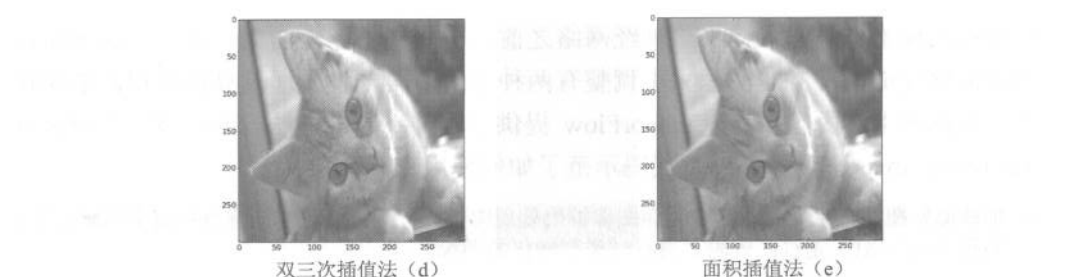
Method 取值	图像大小调整算法
0	双线性插值法 (Bilinear interpolation) ①
1	最近邻居法 (Nearest neighbor interpolation) ②
2	双三次插值法 (Bicubic interpolation) ③
3	面积插值法 (Area interpolation)



① 更详细的介绍可以参考 https://en.wikipedia.org/wiki/Bilinear_interpolation。

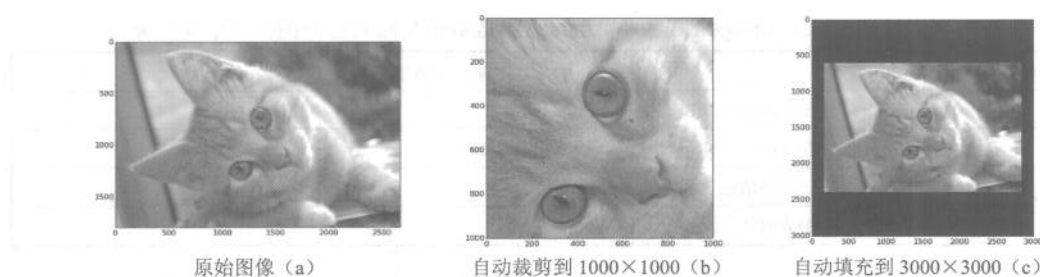
② 更详细的介绍可以参考 https://en.wikipedia.org/wiki/Nearest-neighbor_interpolation。

③ 更详细的介绍可以参考 https://en.wikipedia.org/wiki/Bicubic_interpolation。

图 7-2 使用 `tf.image.resize_images` 函数中不同图像大小调整算法的效果对比图

从图 7-2 中可以看出，不同算法调整出来的结果会有细微差别，但不会相差太远。除了将整张图像信息完整保存，TensorFlow 还提供了 API 对图像进行裁剪或者填充。以下代码展示了通过 `tf.image.resize_image_with_crop_or_pad` 函数来调整图像大小的功能。

```
# 通过 tf.image.resize_image_with_crop_or_pad 函数调整图像的大小。这个函数的
# 第一个参数为原始图像，后面两个参数是调整后的目标图像大小。如果原始图像的尺寸大于目标
# 图像，那么这个函数会自动截取原始图像中居中的部分（如图 7-3 (b) 所示）。如果目标图像
# 大于原始图像，这个函数会自动在原始图像的四周填充全 0 背景（如图 7-3 (c) 所示）。因为原
# 始图像的大小为 1797×2673，所以下面的第一个命令会自动剪裁，而第二个命令会自动填充。
cropped = tf.image.resize_image_with_crop_or_pad(img_data, 1000, 1000)
padded = tf.image.resize_image_with_crop_or_pad(img_data, 3000, 3000)
```

图 7-3 使用 `tf.image.resize_image_with_crop_or_pad` 函数调整图像大小结果对比图

TensorFlow 还支持通过比例调整图像大小，以下代码给出了一个样例。

```
# 通过 tf.image.central_crop 函数可以按比例裁剪图像。这个函数的第一个参数为原始图
# 像，第二个为调整比例，这个比例需要是一个(0,1]的实数。图 7-4 (b) 中显示了调整之
# 后的图像。
central_cropped = tf.image.central_crop(img_data, 0.5)
```

上面介绍的图像裁剪函数都是截取或者填充图像中间的部分。TensorFlow 也提供了 `tf.image.crop_to_bounding_box` 函数和 `tf.image.pad_to_bounding_box` 函数来剪裁或者填充给定区域的图像。这两个函数都要求给出的尺寸满足一定的要求，否则程序会报错。比如在使用 `tf.image.crop_to_bounding_box` 函数时，TensorFlow 要求提供的图像尺寸要大于目标尺

寸，也就是要求原始图像能够裁剪出目标图像的大小。这里就不再给出每个函数的具体样例，有兴趣的读者可以自行参考 TensorFlow 的 API 文档。




图 7-4 使用 `tf.image.central_crop` 函数调整图像大小结果对比图

图像翻转

TensorFlow 提供了一些函数来支持对图像的翻转。以下代码实现了将图像上下翻转、左右翻转以及沿对角线翻转的功能。

```
# 将图像上下翻转，翻转后的效果见图 7-5(b)。
flipped = tf.image.flip_up_down(img_data)
# 将图像左右翻转，翻转后的效果见图 7-5(c)。
flipped = tf.image.flip_left_right(img_data)
# 将图像沿对角线翻转，翻转后的效果见图 7-5(d)。
transposed = tf.image.transpose_image(img_data)
```




图 7-5 图像翻转效果图

在很多图像识别问题中，图像的翻转不会影响识别的结果。于是在训练图像识别的神经网络模型时，可以随机地翻转训练图像，这样训练得到的模型可以识别不同角度的实体。比如假设在训练数据中所有的猫头都是向右的，那么训练出来的模型就无法很好的识别猫头向左的猫。虽然这个问题可以通过收集更多的训练数据来解决，但是通过随机翻转训练图像的方式可以在零成本的情况下很大程度地缓解该问题。所以随机翻转训练图像是一种很常用的图像预处理方式。TensorFlow 提供了方便的 API 完成随机图像翻转的过程。

```
# 以一定概率上下翻转图像。
flipped = tf.image.random_flip_up_down(img_data)
# 以一定概率左右翻转图像。
flipped = tf.image.random_flip_left_right(img_data)
```

图像色彩调整

和图像翻转类似，调整图像的亮度、对比度、饱和度和色相在很多图像识别应用中都不会影响识别结果。所以在训练神经网络模型时，可以随机调整训练图像的这些属性，从而使得训练得到的模型尽可能小地受到无关因素的影响。TensorFlow 提供了调整这些色彩相关属性的 API。以下代码显示了如何修改图像的亮度。

```
# 将图像的亮度-0.5，得到的图像效果如图 7-6(b) 所示。
adjusted = tf.image.adjust_brightness(img_data, -0.5)
# 将图像的亮度+0.5，得到的图像效果如图 7-6(c) 所示。
adjusted = tf.image.adjust_brightness(img_data, 0.5)
# 在[-max_delta, max_delta)的范围随机调整图像的亮度。
adjusted = tf.image.random_brightness(image, max_delta)
```




图 7-6 图像亮度调整效果图^①

以下代码显示了如何调整图像的对比度。

```
# 将图像的对比度-5，得到的图像效果如图 7-7(b) 所示。
adjusted = tf.image.adjust_contrast(img_data, -5)
# 将图像的对比度+5，得到的图像效果如图 7-7(c) 所示。
adjusted = tf.image.adjust_contrast(img_data, 5)
```

^① 在黑白图片上色相的调整不是特别明显，在彩色图片上的效果会比较明显。

```
# 在[lower, upper]的范围随机调整图的对比度。
adjusted = tf.image.random_contrast(image, lower, upper)
```



图 7-7 图像对比度调整效果图

以下代码显示了如何调整图像的色相。

```
# 下面四条命令分别将色相加 0.1、0.3、0.6 和 0.9, 得到的效果分别在
# 图 7-8 (b), (c), (d), (e) 中展示。
adjusted = tf.image.adjust_hue(img_data, 0.1)
adjusted = tf.image.adjust_hue(img_data, 0.3)
adjusted = tf.image.adjust_hue(img_data, 0.6)
adjusted = tf.image.adjust_hue(img_data, 0.9)
# 在[-max_delta, max_delta]的范围随机调整图像的色相。
# max_delta 的取值在[0, 0.5]之间。
adjusted = tf.image.random_hue(image, max_delta)
```




图 7-8 图像色相调整效果图

以下代码显示了如何调整图像的饱和度。

```
# 将图像的饱和度-5，得到的图像效果如图 7-9 (b) 所示。
adjusted = tf.image.adjust_saturation(img_data, -5)
# 将图像的饱和度+5，得到的图像效果如图 7-9 (c) 所示。
adjusted = tf.image.adjust_saturation(img_data, 5)
# 在[lower, upper]的范围随机调整图的饱和度。
adjusted = tf.image.random_saturation(image, lower, upper)
```



图 7-9 图像饱和度调整效果图

除了调整图像的亮度、对比度、饱和度和色相，TensorFlow 还提供 API 来完成图像标准化的过程。这个操作就是将图像上的亮度均值变为 0，方差变为 1。以下代码实现了这个功能。

```
# 将代表一张图像的三维矩阵中的数字均值变为 0，方差变为 1。调整后的图像如图 7-10 (b)。
adjusted = tf.image.per_image_whitening(img_data)
```




图 7-10 图像标准化效果图

处理标注框

在很多图像识别的数据集中，图像中需要关注的物体通常会被标注框圈出来。TensorFlow 提供了一些工具来处理标注框。下面这段代码展示了如何通过 `tf.image.draw_bounding_boxes` 函数在图像中加入标注框。

```

# 将图像缩小一些, 这样可视化能让标注框更加清楚。
img_data = tf.image.resize_images(img_data, 180, 267, method=1)
# tf.image.draw_bounding_boxes 函数要求图像矩阵中的数字为实数, 所以需要将
# 图像矩阵转化为实数类型。tf.image.draw_bounding_boxes 函数图像的输入是一个
# batch 的数据, 也就是多张图像组成的四维矩阵, 所以需要将解码之后的图像矩阵加一维。
batched = tf.expand_dims(
    tf.image.convert_image_dtype(img_data, tf.float32), 0)
# 给出每一张图像的所有标注框。一个标注框有四个数字, 分别代表  $[y_{min} \ x_{min} \ y_{max} \ x_{max}]$ 。
# 注意这里给出的数字都是图像的相对位置。比如在  $180 \times 267$  的图像中,
#  $[0.35, 0.47, 0.5, 0.56]$  代表了从  $(63, 125)$  到  $(90, 150)$  的图像。
boxes = tf.constant([[[0.05, 0.05, 0.9, 0.7], [0.35, 0.47, 0.5, 0.56]]])
# 图 7-11 显示了加入了标注框的图像。
result = tf.image.draw_bounding_boxes(batched, boxes)

```




图 7-11 在图像中加入标注框(图中大的标注框标明了猫脸的位置, 小的标注框标明了猫的一只眼睛的位置)

和随机翻转图像、随机调整颜色类似, 随机截取图像上有信息含量的部分也是一个提高模型健壮性 (robustness) 的一种方式。这样可以使训练得到的模型不受被识别物体大小的影响。下面的程序中展示了如何通过 `tf.image.sample_distorted_bounding_box` 函数来完成随机截取图像的过程。

```

boxes = tf.constant([[[0.05, 0.05, 0.9, 0.7], [0.35, 0.47, 0.5, 0.56]]])
# 可以通过提供标注框的方式来告诉随机截取图像的算法哪些部分是“有信息量”的。
begin, size, bbox_for_draw = tf.image.sample_distorted_bounding_box(
    tf.shape(img_data), bounding_boxes=boxes)

# 通过标注框可视化随机截取得到的图像。得到的结果如图 7-12 左侧所示。
batched = tf.expand_dims(
    tf.image.convert_image_dtype(img_data, tf.float32), 0)
image_with_box = tf.image.draw_bounding_boxes(batched, bbox_for_draw)
# 截取随机出来的图像。得到的结果如图 7-12 右侧所示。因为算法带有随机成分, 所以
# 每次得到的结果会有所不同。
distorted_image = tf.slice(img_data, begin, size)

```




图 7-12 在图像中随机加入的标注框（左）以及通过这个标注框截取图像（右）

7.2.2 图像预处理完整样例

在 7.2.1 小节中详细讲解了 TensorFlow 提供的主要的图像处理函数。在解决真实的图像识别问题时，一般会同时使用多种处理方法。这一个小节将给出一个完整的样例程序展示如何将不同的图像处理函数结合成一个完成的图像预处理流程。以下 TensorFlow 程序完成了从图像片段截取，到图像大小调整再到图像翻转及色彩调整的整个图像预处理过程。

```
import tensorflow as tf

import numpy as np
import matplotlib.pyplot as plt

# 给定一张图像，随机调整图像的色彩。因为调整亮度、对比度、饱和度和色相的顺序会影响最后得到的结果，所以可以定义多种不同的顺序。具体使用哪一种顺序可以在训练数据预处理时随机的选择一种。这样可以进一步降低无关因素对模型的影响。
def distort_color(image, color_ordering=0):
    if color_ordering == 0:
        image = tf.image.random_brightness(image, max_delta=32. / 255.)
        image = tf.image.random_saturation(image, lower=0.5, upper=1.5)
        image = tf.image.random_hue(image, max_delta=0.2)
        image = tf.image.random_contrast(image, lower=0.5, upper=1.5)
    elif color_ordering == 1:
        image = tf.image.random_saturation(image, lower=0.5, upper=1.5)
        image = tf.image.random_brightness(image, max_delta=32. / 255.)
        image = tf.image.random_contrast(image, lower=0.5, upper=1.5)
        image = tf.image.random_hue(image, max_delta=0.2)
    elif color_ordering == 2:
        # 还可以定义其他的排列，但在这里就不再一一列出。
```

```

...
return tf.clip_by_value(image, 0.0, 1.0)

# 给定一张解码后的图像、目标图像的尺寸以及图像上的标注框，此函数可以对给出的图像进行预
# 处理。这个函数的输入图像是图像识别问题中原始的训练图像，而输出则是神经网络模型的输入
# 层。注意这里只处理模型的训练数据，对于预测的数据，一般不需要使用随机变换的步骤。
def preprocess_for_train(image, height, width, bbox):
    # 如果没有提供标注框，则认为整个图像就是需要关注的部分。
    if bbox is None:
        bbox = tf.constant([0.0, 0.0, 1.0, 1.0],
                           dtype=tf.float32, shape=[1, 1, 4])
    # 转换图像张量的类型。
    if image.dtype != tf.float32:
        image = tf.image.convert_image_dtype(image, dtype=tf.float32)

    # 随机截取图像，减小需要关注的物体大小对图像识别算法的影响。
    bbox_begin, bbox_size, _ = tf.image.sample_distorted_bounding_box(
        tf.shape(image), bounding_boxes=bbox)
    distorted_image = tf.slice(image, bbox_begin, bbox_size)
    # 将随机截取的图像调整为神经网络输入层的大小。大小调整的算法是随机选择的。
    distorted_image = tf.image.resize_images(
        distorted_image, height, width, method=np.random.randint(4))
    # 随机左右翻转图像。
    distorted_image = tf.image.random_flip_left_right(distorted_image)
    # 使用一种随机的顺序调整图像色彩。
    distorted_image = distort_color(distorted_image, np.random.randint(2))
    return distorted_image

image_raw_data = tf.gfile.GFile("/path/to/picture", "r").read()
with tf.Session() as sess:
    img_data = tf.image.decode_jpeg(image_raw_data)
    boxes = tf.constant([[[0.05, 0.05, 0.9, 0.7], [0.35, 0.47, 0.5, 0.56]]])

    # 运行6次获得6种不同的图像，在图7-13展示了这些图像的效果。
    for i in range(6):
        # 将图像的尺寸调整为299×299。
        result = preprocess_for_train(img_data, 299, 299, boxes)
        plt.imshow(result.eval())
        plt.show()

```





图 7-13 运行 6 次图像预处理得出的 6 张不同的图像

运行上面这段程序，可以得到类似图 7-13 中所示的图像。这样就可以通过一张训练图像衍生出很多训练样本。通过将训练图像进行预处理，训练得到的神经网络模型可以识别不同大小、方位、色彩等方面的实体。

7.3 多线程输入数据处理框架

在 7.2 节中介绍了使用 TensorFlow 对图像数据进行预处理的方法。虽然使用这些图像数据预处理的方法可以减小无关因素对图像识别模型效果的影响，但这些复杂的预处理过程也会减慢整个训练过程^①。为了避免图像预处理成为神经网络模型训练效率的瓶颈，TensorFlow 提供了一套多线程处理输入数据的框架。在本节中将详细介绍这个框架。图 7-14 总结了一个经典的输入数据处理的流程，在以下的各个小节中，将依次介绍这个流程的不同部分。

^① 本章中主要以图像识别应用为背景介绍数据预处理流程，但读者可以很容易将这个框架应用到其他类型的数据上。




图 7-14 经典输入数据处理流程图

7.3.1 小节将首先介绍 TensorFlow 中队列的概念。在 TensorFlow 中，队列不仅是一种数据结构，它更提供了多线程机制。队列也是 TensorFlow 多线程输入数据处理框架的基础。然后在 7.3.2 小节中将介绍如何在 TensorFlow 中实现图 7-14 中的前三步。TensorFlow 提供了 `tf.train.string_input_producer` 函数来有效管理原始输入文件列表。在 7.3.2 小节中将重点介绍如何使用这个函数。图 7-14 中数据预处理的部分已经在 7.2 节中有过详细介绍，本节不再重复。接着在 7.3.3 小节中将介绍图 7-14 中的最后一个流程。这个流程将处理好的单个训练数据整理成训练数据 batch，这些 batch 就可以作为神经网络的输入。7.3.3 小节将介绍 `tf.train.shuffle_batch_join` 和 `tf.train.shuffle_batch` 函数，并比较不同函数的多线程并行方式。最后在 7.3.4 小节中将给出一个完整的 TensorFlow 程序来展示整个输入数据处理框架。

7.3.1 队列与多线程

在 TensorFlow 中，队列和变量类似，都是计算图上有状态的节点。其他的计算节点可以修改它们的状态。对于变量，可以通过赋值操作修改变量的取值^①。对于队列，修改队列状态的操作主要有 `Enqueue`、`EnqueueMany` 和 `Dequeue`。以下程序展示了如何使用这些函数来操作一个队列。

```
import tensorflow as tf

# 创建一个先进先出队列，指定队列中最多可以保存两个元素，并指定类型为整数。
q = tf.FIFOQueue(2, "int32")
```

① 第 4 章中详细介绍了 TensorFlow 中的变量。

```

# 使用 enqueue_many 函数来初始化队列中的元素。和变量初始化类似，在使用队列之前
# 需要明确的调用这个初始化过程。
init = q.enqueue_many([0, 10],)
# 使用 Dequeue 函数将队列中的第一个元素出队列。这个元素的值将被存在变量 x 中。
x = q.dequeue()
# 将得到的值加 1。
y = x + 1
# 将加 1 后的值在重新加入队列。
q_inc = q.enqueue([y])

with tf.Session() as sess:
    # 运行初始化队列的操作。
    init.run()
    for _ in range(5):
        # 运行 q_inc 将执行数据出队列、出队的元素+1、重新加入队列的整个过程。
        v, _ = sess.run([x, q_inc])
        # 打印出队元素的取值。
        print v
'''
队列开始有 [0,10] 两个元素，第一个出队的为 0，加 1 之后再次入队得到的队列为 [10,1]；第二次出队的为 10，加 1 之后入队的为 11，得到的队列为 [1,11]；以此类推，最后得到的输出为：
0
10
1
11
2
'''

```

TensorFlow 中提供了 `FIFOQueue` 和 `RandomShuffleQueue` 两种队列。在上面的程序中，已经展示了如何使用 `FIFOQueue`，它的实现的是一个先进先出队列。`RandomShuffleQueue` 会将队列中的元素打乱，每次出队列操作得到的是从当前队列所有元素中随机选择的一个。在训练神经网络时希望每次使用的训练数据尽量随机，`RandomShuffleQueue` 就提供了这样的功能。

在 TensorFlow 中，队列不仅仅是一种数据结构，还是异步计算张量取值的一个重要机制。比如多个线程可以同时向一个队列中写元素，或者同时读取一个队列中的元素。在后面的小节中将具体介绍 TensorFlow 是如何利用队列来实现多线程输入数据处理的。在本小节之后的内容中将先介绍 TensorFlow 提供的辅助函数来更好地协同不同的线程。

TensorFlow 提供了 `tf.Coordinator` 和 `tf.QueueRunner` 两个类来完成多线程协同的功能。`tf.Coordinator` 主要用于协同多个线程一起停止，并提供了 `should_stop`、`request_stop` 和 `join`

三个函数。在启动线程之前，需要先声明一个 `tf.Coordinator` 类，并将这个类传入每一个创建的线程中。启动的线程需要一直查询 `tf.Coordinator` 类中提供的 `should_stop` 函数，当这个函数的返回值为 `True` 时，则当前线程也需要退出。每一个启动的线程都可以通过调用 `request_stop` 函数来通知其他线程退出。当某一个线程调用 `request_stop` 函数之后，`should_stop` 函数的返回值将被设置为 `True`，这样其他的线程就可以同时终止了。以下程序展示了如何使用 `tf.Coordinator`。

```
import tensorflow as tf
import numpy as np
import threading
import time

# 线程中运行的程序，这个程序每隔 1 秒判断是否需要停止并打印自己的 ID。
def MyLoop(coord, worker_id):
    # 使用 tf.Coordinator 类提供的协同工具判断当前线程是否需要停止。
    while not coord.should_stop():
        # 随机停止所有的线程。
        if np.random.rand() < 0.1 :
            print "Stoping from id: %d\n" % worker_id,
            # 调用 coord.request_stop() 函数来通知其他线程停止。
            coord.request_stop()
        else:
            # 打印当前线程的 Id。
            print "Working on id: %d\n" % worker_id,
            # 暂停 1 秒
            time.sleep(1)

# 声明一个 tf.train.Coordinator 类来协同多个线程。
coord = tf.train.Coordinator()
# 声明创建 5 个线程。
threads = [
    threading.Thread(target=MyLoop, args=(coord, i, )) for i in xrange(5)]
# 启动所有的线程。
for t in threads: t.start()
# 等待所有线程退出。
coord.join(threads)
```

运行上面的程序，可以得到类似下面的结果：

```
Working on id: 0
Working on id: 1
```

```

Working on id: 2
Working on id: 4
Working on id: 3
Working on id: 0
Stoping from id: 4
Working on id: 1

```

当所有线程启动之后，每个线程会打印各自的 ID，于是前面 4 行打印出了它们的 ID。然后在暂停 1 秒之后，所有线程又开始第二遍打印 ID。在这个时候有一个线程退出的条件达到，于是调用了 `coord.request_stop` 函数来停止所有其他的线程。然而在打印 `Stoping from id: 4` 之后，可以看到有线程仍然在输出。这是因为这些线程已经执行完 `coord.should_stop` 的判断，于是仍然会继续输出自己的 ID。但在下一轮判断是否需要停止时将退出线程。于是在打印一次 ID 之后就不会再有输出了。

`tf.QueueRunner` 主要用于启动多个线程来操作同一个队列，启动的这些线程可以通过上面介绍的 `tf.Coordinator` 类来统一管理。以下代码展示了如何使用 `tf.QueueRunner` 和 `tf.Coordinator` 来管理多线程队列操作。

```

import tensorflow as tf

# 声明一个先进先出的队列，队列中最多 100 个元素，类型为实数。
queue = tf.FIFOQueue(100, "float")
# 定义队列的入队操作。
enqueue_op = queue.enqueue([tf.random_normal([1])])

# 使用 tf.train.QueueRunner 来创建多个线程运行队列的入队操作。
# tf.train.QueueRunner 的第一个参数给出了被操作的队列，[enqueue_op] * 5
# 表示了需要启动 5 个线程，每个线程中运行的是 enqueue_op 操作。
qr = tf.train.QueueRunner(queue, [enqueue_op] * 5)

# 将定义过的 QueueRunner 加入 TensorFlow 计算图上指定的集合。
# tf.train.add_queue_runner 函数没有指定集合，
# 则加入默认集合 tf.GraphKeys.QUEUE_RUNNERS①。下面的函数就是将刚刚定义的
# qr 加入默认的 tf.GraphKeys.QUEUE_RUNNERS 集合。
tf.train.add_queue_runner(qr)
# 定义出队操作。
out_tensor = queue.dequeue()

with tf.Session() as sess:

```

① 第 3 章介绍了 TensorFlow 计算图中集合的概念。

```

# 使用 tf.train.Coordinator 来协同启动的线程。
coord = tf.train.Coordinator()
# 使用 tf.train.QueueRunner 时，需要明确调用 tf.train.start_queue_runners
# 来启动所有线程。否则因为没有线程运行入队操作，当调用出队操作时，程序会一直等待入
# 队操作被运行。tf.train.start_queue_runners 函数会默认启动
# tf.GraphKeys.QUEUE_RUNNERS 集合中所有的 QueueRunner。因为这个函数只支持启
# 动指定集合中的 QueueRunner，所以一般来说 tf.train.add_queue_runner 函数和
# tf.train.start_queue_runners 函数会指定同一个集合。
threads = tf.train.start_queue_runners(sess=sess, coord=coord)
# 获取队列中的取值。
for _ in range(3): print sess.run(out_tensor)[0]

# 使用 tf.train.Coordinator 来停止所有的线程。
coord.request_stop()
coord.join(threads)

'''
上面的程序将启动五个线程来执行队列入队的操作，其中每一个线程都是将随机数写入队列。于是在
每次运行出队操作时，可以得到一个随机数。运行这段程序可以得到类似下面的结果：
-0.315963
-1.06425
0.347479
'''

```

7.3.2 输入文件队列

本小节将介绍如何使用 TensorFlow 中的队列管理输入文件列表。在这一小节中，假设所有的输入数据都已经整理成了 TFRecord 格式^①。虽然一个 TFRecord 文件中可以存储多个训练样例，但是当训练数据量较大时，可以将数据分成多个 TFRecord 文件来提高处理效率。TensorFlow 提供了 `tf.train.match_filenames_once` 函数来获取符合一个正则表达式的所有文件，得到的文件列表可以通过 `tf.train.string_input_producer` 函数进行有效的管理。

`tf.train.string_input_producer` 函数会使用初始化时提供的文件列表创建一个输入队列，输入队列中原始的元素为文件列表中的所有文件。如 7.1 节中的样例代码所示，创建好的输入队列可以作为文件读取函数的参数。每次调用文件读取函数时，该函数会先判断当前是否已有打开的文件可读，如果没有或者打开的文件已经读完，这个函数会从输入队列中

① TFRecord 格式在 7.1 节中有介绍。

出队一个文件并从这个文件中读取数据。

通过设置 `shuffle` 参数, `tf.train.string_input_producer` 函数支持随机打乱文件列表中文件出队的顺序。当 `shuffle` 参数为 `True` 时, 文件在加入队列之前会被打乱顺序, 所以出队的顺序也是随机的。随机打乱文件顺序以及加入输入队列的过程会跑在一个单独的线程上, 这样不会影响获取文件的速度。`tf.train.string_input_producer` 生成的输入队列可以同时被多个文件读取线程操作, 而且输入队列会将队列中的文件均匀地分给不同的线程, 不出现有些文件被处理过多次而有些文件还没有被处理过的情况。

当一个输入队列中的所有文件都被处理完后, 它会将初始化时提供的文件列表中的文件全部重新加入队列。`tf.train.string_input_producer` 函数可以设置 `num_epochs` 参数来限制加载初始文件列表的最大轮数。当所有文件都已经被使用了设定的轮数后, 如果继续尝试读取新的文件, 输入队列会报 `OutOfRange` 的错误。在测试神经网络模型时, 因为所有测试数据只需要使用一次, 所以可以将 `num_epochs` 参数设置为 1。这样在计算完一轮之后程序将自动停止。在展示 `tf.train.match_filenames_once` 和 `tf.train.string_input_producer` 函数的使用方法之前, 下面先给出一个简单的程序来生成样例数据。

```
import tensorflow as tf

# 创建 TFRecord 文件的帮助函数。
def _int64_feature(value):
    return tf.train.Feature(int64_list=tf.train.Int64List(value=[value]))

# 模拟海量数据情况下将数据写入不同的文件。num_shards 定义了总共写入多少个文件,
# instances_per_shard 定义了每个文件中有多少个数据。
num_shards = 2
instances_per_shard = 2
for i in range(num_shards):
    # 将数据分为多个文件时, 可以将不同文件以类似 0000n-of-0000m 的后缀区分。其中 m 表
    # 示了数据总共被存在了多少个文件中, n 表示当前文件的编号。式样的方式既方便了通过正
    # 则表达式获取文件列表, 又在文件名中加入了更多的信息。
    filename = ('/path/to/data.tfrecords-%.5d-of-%.5d' % (i, num_shards))
    writer = tf.python_io.TFRecordWriter(filename)
    # 将数据封装成 Example 结构并写入 TFRecord 文件。
    for j in range(instances_per_shard):
        # Example 结构仅包含当前样例属于第几个文件以及是当前文件的第几个样本。
        example = tf.train.Example(features=tf.train.Features(feature={
            'i': _int64_feature(i),
            'j': _int64_feature(j)}))
        writer.write(example.SerializeToString())
    writer.close()
```

程序运行之后,在指定的目录下将生成两个文件: /path/to/data.tfrecords-00000-of-00002 和 /path/to/data.tfrecords-00001-of-00002。每一个文件中存储了两个样例。在生成了样例数据之后,以下代码展示了 `tf.train.match_filenames_once` 函数和 `tf.train.string_input_producer` 函数的使用方法。

```
import tensorflow as tf

# 使用 tf.train.match_filenames_once 函数获取文件列表。
files = tf.train.match_filenames_once("/path/to/data.tfrecords-*")

# 通过 tf.train.string_input_producer 函数创建输入队列, 输入队列中的文件列表为
# tf.train.match_filenames_once 函数获取的文件列表。这里将 shuffle 参数设为 False
# 来避免随机打乱读文件的顺序。但一般在解决真实问题时, 会将 shuffle 参数设置为 True。
filename_queue = tf.train.string_input_producer(files, shuffle=False)

# 如 7.1 节中所示读取并解析一个样本。
reader = tf.TFRecordReader()
_, serialized_example = reader.read(filename_queue)
features = tf.parse_single_example(
    serialized_example,
    features={
        'i': tf.FixedLenFeature([], tf.int64),
        'j': tf.FixedLenFeature([], tf.int64),
    })

with tf.Session() as sess:
    # 虽然在本段程序中没有声明任何变量, 但使用 tf.train.match_filenames_once 函数时需
    # 要初始化一些变量。
    tf.initialize_all_variables().run()
    '''
    打印文件列表将得到下面的结果:
    ['/path/to/data.tfrecords-00000-of-00002'
     '/path/to/data.tfrecords-00001-of-00002']
    '''
    print sess.run(files)

# 声明 tf.train.Coordinator 类来协同不同线程, 并启动线程。
coord = tf.train.Coordinator()
threads = tf.train.start_queue_runners(sess=sess, coord=coord)

# 多次执行获取数据的操作。
```

```
for i in range(6):
    print sess.run([features['i'], features['j']])
coord.request_stop()
coord.join(threads)
```

上面的打印将输出:

```
[0, 0]
[0, 1]
[1, 0]
[1, 1]
[0, 0]
[0, 1]
```

在不打乱文件列表的情况下, 会依次读出样例数据中的每一个样例。而且当所有样例都被读完之后, 程序会自动从头开始。如果限制 `num_epochs` 为 1, 那么程序将会报错:

```
tensorflow.python.framework.errors.OutOfRangeError: FIFOQueue
'_0_input_producer' is closed and has insufficient elements (requested 1,
current size 0)
[[Node: ReaderRead = ReaderRead[_class=["loc:@TFRecordReader", "loc:
@input_producer"],
_device="/job:localhost/replica:0/task:0/cpu:0"] (TFRecordReader,
input_producer)]]
```

7.3.3 组合训练数据 (batching)

在 7.3.2 小节中已经介绍了如何从文件列表中读取单个样例, 将这些单个样例通过 7.2 节中介绍的预处理方法进行处理, 就可以得到提供给神经网络输入层的训练数据了。在第 4 章介绍过, 将多个输入样例组织成一个 `batch` 可以提高模型训练的效率。所以在得到单个样例的预处理结果之后, 还需要将它们组织成 `batch`, 然后再提供给神经网络的输入层。TensorFlow 提供了 `tf.train.batch` 和 `tf.train.shuffle_batch` 函数来将单个的样例组织成 `batch` 的形式输出。这两个函数都会生成一个队列, 队列的入队操作是生成单个样例的方法, 而每次出队得到的是一个 `batch` 的样例。它们唯一的区别在于是否会将数据顺序打乱。以下代码展示了这两个函数的使用方法。

```
import tensorflow as tf

# 使用 7.3.2 小节中的方法读取并解析得到样例。这里假设 Example 结构中 i 表示一个样例的
# 特征向量, 比如一张图像的像素矩阵。而 j 表示该样例对应的标签。
```

```

example, label = features['i'], features['j']

# 一个batch中样例的个数。
batch_size = 3
# 组合样例的队列中最多可以存储的样例个数。这个队列如果太大，那么需要占用很多内存资源；
# 如果太小，那么出队操作可能会因为没有数据而被阻碍（block），从而导致训练效率降低。一般
# 来说这个队列的大小会和每一个batch的大小相关，下面一行代码给出了设置队列大小的一种
# 方式。
capacity = 1000 + 3 * batch_size

# 使用tf.train.batch函数来组合样例。[example, label]参数给出了需要组合的元素，
# 一般example和label分别代表训练样本和这个样本对应的正确标签。batch_size参数给出
# 了每个batch中样例的个数。capacity给出了队列的最大容量。当队列长度等于容量时，
# TensorFlow将暂停入队操作，而只是等待元素出队。当元素个数小于容量时，TensorFlow
# 将自动重新启动入队操作。
example_batch, label_batch = tf.train.batch(
    [example, label], batch_size=batch_size, capacity=capacity)

with tf.Session() as sess:
    tf.initialize_all_variables().run()
    coord = tf.train.Coordinator()
    threads = tf.train.start_queue_runners(sess=sess, coord=coord)

    # 获取并打印组合之后的样例。在真实问题中，这个输出一般会作为神经网络的输入。
    for i in range(2):
        cur_example_batch, cur_label_batch = sess.run(
            [example_batch, label_batch])
        print cur_example_batch, cur_label_batch

    coord.request_stop()
    coord.join(threads)

'''
运行上面的程序可以得到下面的输出：
[0 0 1] [0 1 0]
[1 0 0] [1 0 1]
从这个输出可以看到tf.train.batch函数可以将单个的数据组织成3个一组的batch。
在example, label中读到的数据依次为：
example: 0, label:0
example: 0, label:1
example: 1, label:0
example: 1, label:1
这是因为tf.train.batch函数不会随机打乱顺序，所以组合之后得到的数据组合成了上面给出

```

的输出。

下面一段代码展示了 `tf.train.shuffle_batch` 函数的使用方法。

```
# 和 tf.train.batch 的样例代码一样产生 example 和 label。
example, label = features['i'], features['j']

# 使用 tf.train.shuffle_batch 函数来组合样例。tf.train.shuffle_batch 函数
# 的参数大部分都和 tf.train.batch 函数相似，但是 min_after_dequeue 参数是
# tf.train.shuffle_batch 函数特有的。min_after_dequeue 参数限制了出队时队列中元
# 素的最少个数。当队列中元素太少时，随机打乱样例顺序的作用就不大了。所以
# tf.train.shuffle_batch 函数提供了限制出队时最少元素的个数来保证随机打乱顺序的
# 作用。当出队函数被调用但是队列中元素不够时，出队操作将等待更多的元素入队才会完成。
# 如果 min_after_dequeue 参数被设定，capacity 也应该相应调整来满足性能需求。
example_batch, label_batch = tf.train.shuffle_batch(
    [example, label], batch_size=batch_size,
    capacity=capacity, min_after_dequeue=30)

# 和 tf.train.batch 的样例代码一样打印 example_batch, label_batch。

'''
运行上面的代码可以得到下面的输出：
[0 1 1] [0 1 0]
[1 0 0] [0 0 1]
从输出中可以看到，得到的样例顺序已经被打乱了。
'''
```

`tf.train.batch` 函数和 `tf.train.shuffle_batch` 函数除了可以将单个训练数据整理成输入 batch，也提供了并行化处理输入数据的方法。`tf.train.batch` 函数和 `tf.train.shuffle_batch` 函数并行化的方式一致，所以在本小节中仅以应用得更多的 `tf.train.shuffle_batch` 函数为例。通过设置 `tf.train.shuffle_batch` 函数中的 `num_threads` 参数，可以指定多个线程同时执行入队操作。`tf.train.shuffle_batch` 函数的入队操作就是数据读取以及预处理的过程。当 `num_threads` 参数大于 1 时，多个线程会同时读取一个文件中的不同样例并进行预处理。如果需要多个线程处理不同文件中的样例时，可以使用 `tf.train.shuffle_batch_join` 函数^①。此函数会从输入文件队列中获取不同的文件分配给不同的线程。一般来说，输入文件队列是通过 7.3.2 中介绍的 `tf.train.string_input_producer` 函数生成的。这个函数会平均分配文件以保证不同文件中的数据会被尽量平均地使用。

① 如果不需要随机打乱输入数据顺序，可以使用 `tf.train.batch_join` 函数完成类似功能。

`tf.train.shuffle_batch` 函数和 `tf.train.shuffle_batch_join` 函数都可以完成多线程并行的方式来进行数据预处理，但它们各有优劣。对于 `tf.train.shuffle_batch` 函数，不同线程会读取同一个文件。如果一个文件中的样例比较相似（比如都属于同一个类别），那么神经网络的训练效果有可能会受到影响。所以在使用 `tf.train.shuffle_batch` 函数时，需要尽量将同一个 TFRecord 文件中的样例随机打乱。而使用 `tf.train.shuffle_batch_join` 函数时，不同线程会读取不同文件。如果读取数据的线程数比总文件数还大，那么多个线程可能会读取同一个文件中相近部分的数据。而且多个线程读取多个文件可能导致过多的硬盘寻址，从而使得读取效率降低。不同的并行化方式各有所长，具体采用哪一种方法需要根据具体情况来确定。

7.3.4 输入数据处理框架

在前面的小节中已经介绍了图 7-14 所展示的流程图中的所有步骤。在这一小节将把这些步骤串成一个完成的 TensorFlow 来处理输入数据。以下代码给出了这个完成的程序。

```
import tensorflow as tf

# 创建文件列表，并通过文件列表创建输入文件队列。在调用输入数据处理流程前，需要
# 统一所有原始数据的格式并将它们存储到 TFRecord 文件中。下面给出的文件列表应该包含所
# 有提供训练数据的 TFRecord 文件。
files = tf.train.match_filenames_once("/path/to/file_pattern-*")
filename_queue = tf.train.string_input_producer(files, shuffle=False)

# 使用类似 7.1 节中介绍的方法解析 TFRecord 文件里的数据。这里假设 image 中存储的是图像
# 的原始数据，label 为该样例所对应的标签。height、width 和 channels 给出了图片的维度。
reader = tf.TFRecordReader()
_, serialized_example = reader.read(filename_queue)
features = tf.parse_single_example(
    serialized_example,
    features={
        'image': tf.FixedLenFeature([], tf.string),
        'label': tf.FixedLenFeature([], tf.int64),
        'height': tf.FixedLenFeature([], tf.int64),
        'width': tf.FixedLenFeature([], tf.int64),
        'channels': tf.FixedLenFeature([], tf.int64),
    })
image, label = features['image'], features['label']
height, width = features['height'], features['width']
channels = features['channels']
```



```
# 从原始图像数据解析出像素矩阵，并根据图像尺寸还原图像。
decoded_image = tf.decode_raw(image, tf.uint8)
decoded_image.set_shape([height, width, channels])
# 定义神经网络输入层图片的大小。
image_size = 299
# preprocess_for_train 为 7.2.2 小节中介绍的图像预处理程序。
distorted_image = preprocess_for_train(
    decoded_image, image_size, image_size, None)

# 将处理后的图像和标签数据通过 tf.train.shuffle_batch 整理成神经网络训练时
# 需要的 batch。
min_after_dequeue = 10000
batch_size = 100
capacity = min_after_dequeue + 3 * batch_size
image_batch, label_batch = tf.train.shuffle_batch(
    [distorted_image, label], batch_size=batch_size,
    capacity=capacity, min_after_dequeue=min_after_dequeue)

# 定义神经网络的结构以及优化过程。image_batch 可以作为输入提供给神经网络的输入层。
# label_batch 则提供了输入 batch 中样例的正确答案。
logit = inference(image_batch)
loss = calc_loss(logit, label_batch)
train_step = tf.train.GradientDescentOptimizer(learning_rate)\
    .minimize(loss)

# 声明会话并运行神经网络的优化过程。
with tf.Session() as sess:
    # 神经网络训练准备工作。这些工作包括变量初始化、线程启动。
    tf.initialize_all_variables().run()
    coord = tf.train.Coordinator()
    threads = tf.train.start_queue_runners(sess=sess, coord=coord)

    # 神经网络训练过程。
    for i in range(TRAINING_ROUDNS):
        sess.run(train_step)

    # 停止所有线程。
    coord.request_stop()
    coord.join(threads)
```

图 7-15 展示了以上代码中输入数据处理的整个流程。从图 7-15 中可以看出，输入数据处理的的第一步为获取存储训练数据的文件列表。在图 7-15 中，这个文件列表为{A,B,C}。通过 `tf.train.string_input_producer` 函数，可以选择性地将文件列表中文件的顺序打乱，并加入输入队列。因为是否打乱文件的顺序是可选的，所以在图中通过虚线表示。`tf.train.string_input_producer` 函数会生成并维护一个输入文件队列，不同线程中的文件读取函数可以共享这个输入文件队列。在读取样例数据之后，需要将图像进行预处理。图像预处理的过程也会通过 `tf.train.shuffle_batch` 提供的机制并行地跑在多个线程中。输入数据处理流程的最后通过 `tf.train.shuffle_batch` 函数将处理好的单个输入样例整理成 batch 提供给神经网络的输入层。通过这种方式，可以有效地提高数据预处理的效率，避免数据预处理成为神经网络模型训练过程中的性能瓶颈。




图 7-15 输入数据处理流程示意图

小结

本章通过图像数据预处理的流程，介绍了 TensorFlow 使用多线程处理输入数据的框架。虽然本章以图像数据处理为例，但读者可以很容易将该框架移植到其他类型的数据预处理上。根据输入数据处理的步骤，在本章的三节中分别介绍了 TensorFlow 推荐的输入数据格式、图像预处理算法和输入数据处理的框架。首先在 7.1 节中介绍了如何通过 TensorFlow 提供的 TFRecord 格式来统一不同格式的输入数据。这一节给出了样例程序将原始的输入数据转化为 Example Protocol Buffer，并存储到 TFRecord 文件中，也给出了具体代码从 TFRecord 文件中读取数据。

接着 7.2 节介绍了 TensorFlow 中主要的图像处理函数，并给出了一个完整的图像预处理过程。TensorFlow 提供了图像解码、图像大小调整、图像旋转、图像色彩调整和图像标注框处理等方法。根据具体问题，可以采用其中的部分方法来弱化与此问题无关的因素。比如对于数字手写体识别问题，图像的颜色、亮度等与识别的结果无关，所以可以通过 7.2 节中介绍的方法来弱化这些因素对最终分析结果的影响。

最后 7.3 节介绍了 TensorFlow 提供的多线程数据预处理流程。这一节讲解了 TensorFlow 通过队列实现多线程的机制，并介绍了 TensorFlow 提供的函数来进一步支持并行化的处理输入数据。在这一节中还给出了一个完整的数据预处理流程图和 TensorFlow 程序框架。

第 8 章 循环神经网络

第 6 章中讲解了卷积神经网络的网络结构，并介绍了如何使用卷积神经网络解决图像识别问题。本章中将介绍另外一种常用的神经网络结构——循环神经网络（recurrent neural network, RNN）以及循环神经网络中的一个重要结构——长短时记忆网络（long short-term memory, LSTM）。本章也将介绍循环神经网络在自然语言处理（natural language processing, NLP）问题以及时序分析问题中的应用，并给出具体的 TensorFlow 程序来解决一些经典的问题。

首先在 8.1 节将介绍循环神经网络的基本知识并通过机器翻译问题说明循环神经网络是如何被应用的。这一节中将给出一个具体的样例来说明一个最简单的循环神经网络的前向传播时是如何工作的。然后在 8.2 节中将介绍循环神经网络中最重要的结构——长短时记忆网络（long short term memory, LSTM）的网络结构。在这一节中将大致介绍 LSTM 结构中的主要元素，并给出具体的 TensorFlow 程序来实现一个使用了 LSTM 结构的循环神经网络。接着在 8.3 节中将介绍一些常用的循环神经网络的变种。最后在 8.4 节中将结合 TensorFlow 对这些网络结构的支持，通过两个经典的循环神经网络模型的应用案例，介绍如何针对语言模型和时序预测两个问题，设计和使用循环神经网络。

8.1 循环神经网络简介^①

循环神经网络（recurrent neural network, RNN）源自于 1982 年由 Saratha Sathasivam 提出的霍普菲尔德网络^②。霍普菲尔德网络因为实现困难，在其提出时并没有被合适地应用。该网络结构也于 1986 年后被全连接神经网络以及一些传统的机器学习算法所取代。然

① 本节内容部分参考了资料 <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>。

② 参见：Sathasivam S. *Logic Learning in Hopfield Networks* [J]. Modern Applied Science, 2009.

而,传统的机器学习算法非常依赖于人工提取的特征,使得基于传统机器学习的图像识别、语音识别以及自然语言处理等问题存在特征提取的瓶颈。而基于全连接神经网络的方法也存在参数太多、无法利用数据中时间序列信息等问题。随着更加有效的循环神经网络结构被不断提出,循环神经网络挖掘数据中的时序信息以及语义信息的深度表达能力被充分利用,并在语音识别、语言模型、机器翻译以及时序分析等方面实现了突破。

循环神经网络的主要用途是处理和预测序列数据。在之前介绍的全连接神经网络或卷积神经网络模型中,网络结构都是从输入层到隐含层再到输出层,层与层之间是全连接或部分连接的,但每层之间的节点是无连接的。考虑这样一个问题,如果要预测句子的下一个单词是什么,一般需要用到当前单词以及前面的单词,因为句子中前后单词并不是独立的。比如,当前单词是“很”,前一个单词是“天空”,那么下一个单词很大概率是“蓝”。循环神经网络的来源就是为了刻画一个序列当前的输出与之前信息的关系。从网络结构上,循环神经网络会记忆之前的信息,并利用之前的信息影响后面结点的输出。也就是说,循环神经网络的隐藏层之间的结点是有连接的,隐藏层的输入不仅包括输入层的输出,还包括上一时刻隐藏层的输出。

图 8-1 展示了一个典型的循环神经网络。对于循环神经网络,一个非常重要的概念就是时刻。循环神经网络会对于每一个时刻的输入结合当前模型的状态给出一个输出。从图 8-1 中可以看到,循环神经网络的主体结构 A 的输入除了来自输入层 X_t ,还有一个循环的边来提供当前时刻的状态。在每一个时刻,循环神经网络的模块 A 会读取 t 时刻的输入 X_t ,并输出一个值 h_t 。同时 A 的状态会从当前步传递到下一步。因此,循环神经网络理论上可以被看作是同一神经网络结构被无限复制的结果。但出于优化的考虑,目前循环神经网络无法做到真正的无限循环,所以,现实中一般会将循环体展开,于是可以得到图 8-2 所展示的结构。




图 8-1 循环神经网络经典结构示意图^①

^① 本章关于循环神经网络的介绍图片部分来自资料 <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>。

在图 8-2 中可以更加清楚的看到循环神经网络在每一个时刻会有一个输入 x_t ，然后根据循环神经网络当前的状态 A_t 提供一个输出 h_t 。而循环神经网络当前的状态 A_t 是根据上一时刻的状态 A_{t-1} 和当前的输入 x_t 共同决定的。从循环神经网络的结构特征可以很容易得出它最擅长解决的问题是与时间序列相关的。循环神经网络也是处理这类问题时最自然的神经网络结构。对于一个序列数据，可以将这个序列上不同时刻的数据依次传入循环神经网络的输入层，而输出可以是对序列中下一个时刻的预测，也可以是对当前时刻信息的处理结果（比如语音识别结果）。循环神经网络要求每一个时刻都有一个输入，但是不一定每个时刻都需要有输出。在过去几年中，循环神经网络已经被广泛地应用在语音识别、语言模型、机器翻译以及时序分析等问题上，并取得了巨大的成功。




图 8-2 循环神经网络按时间展开后的结构

以机器翻译为例来介绍循环神经网络是如何解决实际问题的。循环神经网络中每一个时刻的输入为需要翻译的句子中的单词。如图 8-3 所示，需要翻译的句子为 ABCD，那么循环神经网络第一段每一个时刻的输入就分别是 A、B、C 和 D，然后用“_”作为待翻译句子的结束符。在第一段中，循环神经网络没有输出。从结束符“_”开始，循环神经网络进入翻译阶段。该阶段中每一个时刻的输入是上一个时刻的输出，而最终得到的输出就是句子 ABCD 翻译的结果。从图 8-3 中可以看到句子 ABCD 对应的翻译结果就是 XYZ，而 Q 是代表翻译结束的结束符。




图 8-3 循环神经网络实现序列预测示意图

如之前所介绍，循环神经网络可以被看做是同一神经网络结构在时间序列上被复制多

次的结果，这个被复制多次的结构被称之为循环体。如何设计循环体的网络结构是循环神经网络解决实际问题的关键。和卷积神经网络过滤器中参数是共享的类似，在循环神经网络中，循环体网络结构中的参数在不同时刻也是共享的。

图 8-4 展示了一个使用最简单的循环体结构的循环神经网络，在这个循环体中只使用了一个类似全连接层的神经网络结构。下面将通过图 8-4 中所展示的神经网络来介绍循环神经网络前向传播的完整流程。循环神经网络中的状态是通过一个向量来表示的，这个向量的维度也称为循环神经网络隐藏层的大小，假设其为 h 。从图 8-4 中可以看出，循环体中的神经网络的输入有两部分，一部分为上一时刻的状态，另一部分为当前时刻的输入样本。对于时间序列数据来说（比如不同时刻商品的销量），每一时刻的输入样例可以是当前时刻的数值（比如销量值）；对于语言模型来说，输入样例可以是当前单词对应的单词向量（word embedding）^{①②}。




图 8-4 使用单层全连接神经网络作为循环体的循环神经网络结构图^③

假设输入向量的维度为 x , 那么图 8-4 中循环体的全连接层神经网络的输入大小为 $h+x$ 。也就是将上一时刻的状态与当前时刻的输入拼接成一个大的向量作为循环体中神经网络的输入^④。因为该神经网络的输出为当前时刻的状态, 于是输出层的节点个数也为 h , 循环体

① 关于单词向量的简单介绍可参考第 1 章 1.3 节。

② 关于单词向量更加详细的介绍可以参考论文: Mikolov T, Sutskever I, Chen K, et al. *Distributed Representations of Words and Phrases and their Compositionality*[J]. *Advances in Neural Information Processing Systems*, 2013, 26:3111-3119.

③ 图中中间标有 \tanh 的小方框表示一个使用了 \tanh 作为激活函数的全连接神经网络。

④ 也有资料中将会将上一时刻状态对应的权重和当前时刻输入对应的权重特意分开，但它们的实质是一样的。本节展示样例中为了方便显示，采用了向量拼接的方式；在本节的代码中为了方便代码编写，采用了分开的方式。

中的参数个数为 $(h+x) \times h + h$ 个。从图 8-4 中可以看到，循环体中的神经网络输出不但提供给了下一时刻作为状态，同时也会提供给当前时刻的输出。为了将当前时刻的状态转化为最终的输出，循环神经网络还需要另外一个全连接神经网络来完成这个过程。这和卷积神经网络中最后的全连接层的意义是一样的。类似的，不同时刻用于输出的全连接神经网络中的参数也是一致的。为了让读者对循环神经网络的前向传播有一个更加直观的认识，图 8-5 展示了一个循环神经网络前向传播的具体计算过程。

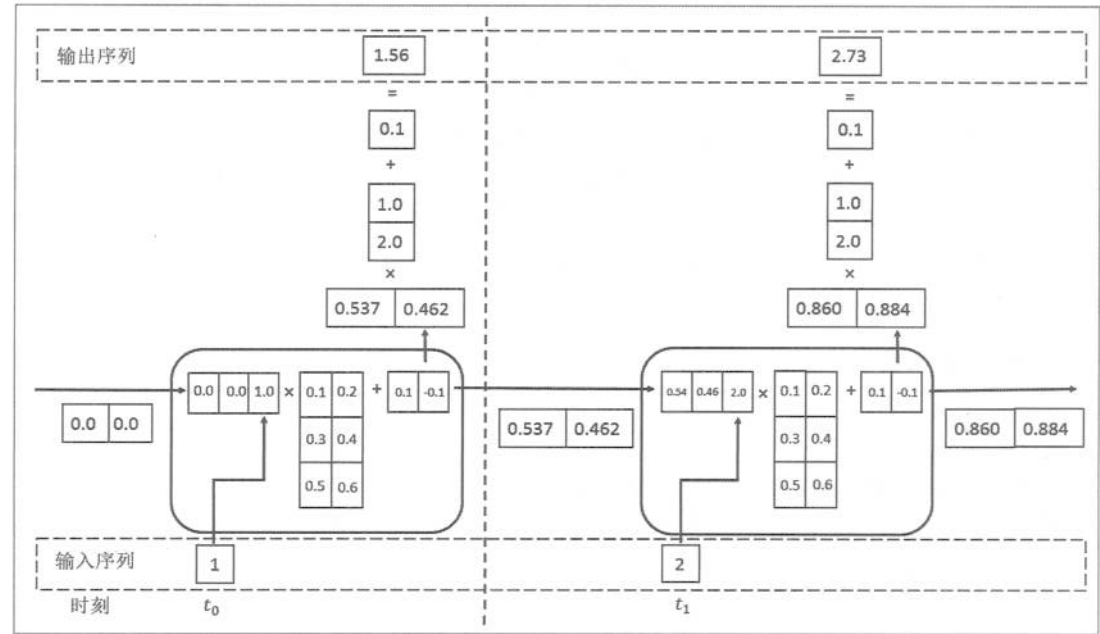


图 8-5 循环神经网络的前向传播的计算过程示意图

在图 8-5 中，假设状态的维度为 2，输入、输出的维度都为 1，而且循环体中的全连接层中权重为：

$$w_{rnn} = \begin{bmatrix} 0.1 & 0.2 \\ 0.3 & 0.4 \\ 0.5 & 0.6 \end{bmatrix}$$

偏置项的大小为 $b_{rnn} = [0.1, -0.1]$ ，用于输出的全连接层权重为：

$$w_{output} = \begin{bmatrix} 1.0 \\ 2.0 \end{bmatrix}$$

偏置项大小为 $b_{output} = 0.1$ 。那么在时刻 t_0 ，因为没有上一时刻，所以将状态初始化为

[0,0], 而当前的输入为 1, 所以拼接得到的向量为[0,0,1], 通过循环体中的全连接层神经网络得到的结果为:

$$\tanh\left([0,0,1] \times \begin{bmatrix} 0.1 & 0.2 \\ 0.3 & 0.4 \\ 0.5 & 0.6 \end{bmatrix} + [0.1, -0.1]\right) = \tanh([0.6, 0.5]) = [0.537, 0.462]$$

这个结果将作为下一时刻的输入状态, 同时循环神经网络也会使用该状态生成输出。将该向量作为输入提供给用于输出的全连接神经网络可以得到 t_0 时刻的最终输出:

$$[0.537, 0.462] \times \begin{bmatrix} 1.0 \\ 2.0 \end{bmatrix} + 0.1 = 1.56$$

使用 t_0 时刻的状态可以类似地推导得出 t_1 时刻的状态为[0.860, 0.884], 而 t_1 时刻的输出为 2.73。在得到循环神经网络的前向传播结果之后, 可以和其他神经网络类似地定义损失函数。循环神经网络唯一的区别在于因为它每个时刻都有一个输出, 所以循环神经网络的总损失为所有时刻(或者部分时刻)上的损失函数的总和。以下代码实现了这个简单的循环神经网络前向传播的过程。

```
import numpy as np

X = [1, 2]
state = [0.0, 0.0]
# 分开定义不同输入部分的权重以方便操作。
w_cell_state = np.asarray([[0.1, 0.2], [0.3, 0.4]])
w_cell_input = np.asarray([0.5, 0.6])
b_cell = np.asarray([0.1, -0.1])

# 定义用于输出的全连接层参数。
w_output = np.asarray([[1.0], [2.0]])
b_output = 0.1

# 按照时间顺序执行循环神经网络的前向传播过程。
for i in range(len(X)):
    # 计算循环体中的全连接层神经网络。
    before_activation = np.dot(state, w_cell_state) +
                        X[i] * w_cell_input + b_cell
    state = np.tanh(before_activation)

    # 根据当前时刻状态计算最终输出。
    final_output = np.dot(state, w_output) + b_output

    # 输出每个时刻的信息。
    print "before activation: ", before_activation
```

```

print "state: ", state
print "output: ", final_output

'''
运行以上程序可以得到输出：
before activation: [ 0.6  0.5]
state: [ 0.53704957  0.46211716]
output: [ 1.56128388]
before activation: [ 1.2923401  1.39225678]
state: [ 0.85973818  0.88366641]
output: [ 2.72707101]
该输出和图 8-5 中的数字是一致的。
'''

```

和其他神经网络类似，在定义完损失函数之后，套用第 4 章中介绍的优化框架 TensorFlow 就可以自动完成模型训练的过程。这里唯一需要特别指出的是，理论上循环神经网络可以支持任意长度的序列，然而在实际中，如果序列过长会导致优化时出现梯度消散的问题（the vanishing gradient problem）^①，所以实际中一般会规定一个最大长度，当序列长度超过规定长度之后会对序列进行截断。

8.2 长短时记忆网络（LSTM）结构

循环神经网络工作的关键点就是使用历史的信息来帮助当前的决策。例如使用之前出现的单词来加强对当前文字的理解。循环神经网络可以更好地利用传统神经网络结构所不能建模的信息，但同时，这也带来了更大的技术挑战——长期依赖（long-term dependencies）问题。

在有些问题中，模型仅仅需要短期内的信息来执行当前的任务。比如预测短语“大海的颜色是蓝色”中的最后一个单词“蓝色”时，模型并不需要记忆这个短语之前更长的上下文信息——因为这一句话已经包含了足够的信息来预测最后一个词。在这样的场景中，相关的信息和待预测的词的位置之间的间隔很小，循环神经网络可以比较容易地利用先前信息。

但同样也会有一些上下文场景更加复杂的情况。比如当模型试着去预测段落“某地开设了大量工厂，空气污染十分严重……这里的天空都是灰色的”的最后一个单词时，仅仅

^① 参见：Gustavsson A, Magnuson A, Blomberg B, et al. *On the difficulty of training Recurrent Neural Networks*[J]. Computer Science, 2013.

根据短期依赖就无法很好的解决这种问题。因为只根据最后一小段，最后一个词可以是“蓝色的”或者“灰色的”。但如果模型需要预测清楚具体是什么颜色，就需要考虑先前提到但离当前位置较远的上下文信息。因此，当前预测位置和相关信息之间的文本间隔就有可能变得很大。当这个间隔不断增大时，类似图 8-4 中给出的简单循环神经网络有可能会丧失学习到距离如此远的信息的能力。或者在复杂语言场景中，有用信息的间隔有大有小、长短不一，循环神经网络的性能也会受到限制。

长短时记忆网络（long short term memory, LSTM）的设计就是为了解决这个问题，而循环神经网络被成功应用的关键就是 LSTM。在很多的任务上，采用 LSTM 结构的循环神经网络比标准的循环神经网络表现更好。在下文中将重点介绍 LSTM 结构。LSTM 结构是由 Sepp Hochreiter 和 Jürgen Schmidhuber^①于 1997 年提出的，它是一种特殊的循环体结构。如图 8-6 所示，与单一 tanh 循环体结构不同，LSTM 是一种拥有三个“门”结构的特殊网络结构。




图 8-6 LSTM 单元结构示意图

LSTM 靠一些“门”的结构让信息有选择性地影响循环神经网络中每个时刻的状态。所谓“门”的结构就是一个使用 sigmoid 神经网络和一个按位做乘法的操作，这两个操作合在一起就是一个“门”的结构。之所以该结构叫做“门”是因为使用 sigmoid 作为激活函数的全连接神经网络层会输出一个 0 到 1 之间的数值，描述当前输入有多少信息量可以通过这个结构。于是这个结构的功能就类似于一扇门，当门打开时（sigmoid 神经网络层输

① Sepp Hochreiter, Jürgen Schmidhuber. Long short-term memory[J]. Neural Computation. 9 (8): 1735~1780,1997.

出为 1 时), 全部信息都可以通过; 当门关上时 (sigmoid 神经网络层输出为 0 时), 任何信息都无法通过。本节下面的篇幅将介绍每一个“门”是如何工作的。

为了使循环神经网络更有效的保存长期记忆, 图 8-6 中“遗忘门”和“输入门”至关重要, 它们是 LSTM 结构的核心。“遗忘门”的作用是让循环神经网络“忘记”之前没有用的信息。比如一段文章中先介绍了某地原来是绿水蓝天, 但后来被污染了。于是在看到被污染了之后, 循环神经网络应该“忘记”之前绿水蓝天的状态。这个工作是通过“遗忘门”来完成的。“遗忘门”会根据当前的输入 x_t 、上一时刻状态 c_{t-1} 和上一时刻输出 h_{t-1} 共同决定哪一部分记忆需要被遗忘。在循环神经网络“忘记”了部分之前的状态后, 它还需要从当前的输入补充最新的记忆。这个过程就是“输入门”完成的。如图 8-6 所示, “输入门”会根据 x_t 、 c_{t-1} 和 h_{t-1} 决定哪些部分将进入当前时刻的状态 c_t 。比如当看到文章中提到环境被污染之后, 模型需要将这个信息写入新的状态。通过“遗忘门”和“输入门”, LSTM 结构可以更加有效的决定哪些信息应该被遗忘, 哪些信息应该得到保留。

LSTM 结构在计算得到新的状态 c_t 后需要产生当前时刻的输出, 这个过程是通过“输出门”完成的。“输出门”会根据最新的状态 c_t 、上一时刻的输出 h_{t-1} 和当前的输入 x_t 来决定该时刻的输出 h_t 。比如当前的状态为被污染, 那么“天空的颜色”后面的单词很可能就是“灰色的”。

相比图 8-4 中展示的循环神经网络, 使用 LSTM 结构的循环神经网络的前向传播是一个相对比较复杂的过程。具体 LSTM 每个“门”中的公式可以参考论文 *Long short-term memory*, 本节不再赘述。在 TensorFlow 中, LSTM 结构可以被很简单地实现。以下代码展示了在 TensorFlow 中实现使用 LSTM 结构的循环神经网络的前向传播过程。

```
# 定义一个 LSTM 结构。在 TensorFlow 中通过一句简单的命令就可以实现一个完整 LSTM 结构。
# LSTM 中使用的变量也会在该函数中自动被声明。
lstm = rnn_cell.BasicLSTMCell(lstm_hidden_size)

# 将 LSTM 中的状态初始化为全 0 数组。和其他神经网络类似, 在优化循环神经网络时, 每次也
# 会使用一个 batch 的训练样本。以下代码中, batch_size 给出了一个 batch 的大小。
# BasicLSTMCell 类提供了 zero_state 函数来生成全 0 的初始状态。
state = lstm.zero_state(batch_size, tf.float32)

# 定义损失函数。
loss = 0.0
# 在 8.1 节中介绍过, 虽然理论上循环神经网络可以处理任意长度的序列, 但是在训练时为了
# 避免梯度消散的问题, 会规定一个最大的序列长度。在以下代码中, 用 num_steps
# 来表示这个长度。
for i in range(num_steps):
    # 在第一个时刻声明 LSTM 结构中使用的变量, 在之后的时刻都需要复用之前定义好的变量。
    if i > 0: tf.get_variable_scope().reuse_variables()
```



```
# 每一步处理时间序列中的一个时刻。将当前输入 (current_input) 和前一时状态
# (state) 传入定义的 LSTM 结构可以得到当前 LSTM 结构的输出 lstm_output 和更新后
# 的状态 state。
lstm_output, state = lstm(current_input, state)
# 将当前时刻 LSTM 结构的输出传入一个全连接层得到最后的输出。
final_output = fully_connected(lstm_output)
# 计算当前时刻输出的损失。
loss += calc_loss(final_output, expected_output)

# 使用类似第 4 章中介绍的方法训练模型。
```

通过上面这段代码看到，通过 TensorFlow 可以非常方便地实现使用 LSTM 结构的循环神经网络，而且并不需要用户对 LSTM 内部结构有深入的了解。

8.3 循环神经网络的变种

在以上几节中已经完整地介绍了使用 LSTM 结构的循环神经网络。这一节将再介绍循环神经网络的几个常用变种以及它们所解决的问题，同时也会给出如何使用 TensorFlow 来实现这些变种。

8.3.1 双向循环神经网络和深层循环神经网络

在经典的循环神经网络中，状态的传输是从前往后单向的。然而，在有些问题中，当前时刻的输出不仅和之前的状态有关系，也和之后的状态相关。这时就需要使用双向循环神经网络 (bidirectional RNN) 来解决这类问题。例如预测一个语句中缺失的单词不仅需要根据前文来判断，也需要根据后面的内容，这时双向循环神经网络就可以发挥它的作用。双向循环神经网络是由两个循环神经网络上下叠加在一起组成的。输出由这两个循环神经网络的状态共同决定。图 8-7 展示了一个双向循环神经网络的结构图。

从图 8-7 中可以看到，双向循环神经网络的主体结构就是两个单向循环神经网络的结合。在每一个时刻 t ，输入会同时提供给这两个方向相反的循环神经网络，而输出则是由这两个单向循环神经网络共同决定。双向循环神经网络的前向传播过程和单向的循环神经网络十分类似，这里就不再赘述。更多关于双向神经网络的介绍可以参考 Mike Schuster 和 Kuldeep K. Paliwal 发表的论文 *Bidirectional recurrent neural networks*^①。

① Schuster M, Paliwal K K. *Bidirectional recurrent neural networks*[J]. IEEE Transactions on Signal Processing, 1997.




图 8-7 双向循环神经网络结构示意图

深层循环神经网络（deepRNN）是循环神经网络的另外一种变种。为了增强模型的表达能力，可以将每一个时刻上的循环体重复多次。图 8-8 给出了深层循环神经网络的结构示意图。从图 8-8 中可以看到，相比 8.1 节中介绍的循环神经网络，深层循环神经网络在每一个时刻上将循环体结构复制了多次。和卷积神经网络类似，每一层的循环体中参数是一致的，而不同层中的参数可以不同。为了更好地支持深层循环神经网络，TensorFlow 中提供了 MultiRNNCell 类来实现深层循环神经网络的前向传播过程。以下代码展示如何使用这个类。




图 8-8 深层循环神经网络结构示意图

```

# 定义一个基本的 LSTM 结构作为循环体的基础结构。深层循环神经网络也支持使用其他的循环
# 体结。
lstm = rnn_cell.BasicLSTMCell(lstm_size)
# 通过 MultiRNNCell 类实现深层循环神经网络中每一个时刻的前向传播过程。其中
# number_of_layers 表示了有多少层，也就是图 8-16 中从  $x_t$  到  $h_t$  需要经过多少个 LSTM 结构。
stacked_lstm = rnn_cell.MultiRNNCell([lstm] * number_of_layers)

# 和经典的循环神经网络一样，可以通过 zero_state 函数来获取初始状态。
state = stacked_lstm.zero_state(batch_size, tf.float32)

# 和 8.2 节中给出的代码一样，计算每一时刻的前向传播结果。
for i in range(len(num_steps)):
    if i > 0: tf.get_variable_scope().reuse_variables()
    stacked_lstm_output, state = stacked_lstm(current_input, state)
    final_output = fully_connected(stacked_lstm_output)
    loss += calc_loss(final_output, expected_output)

```

从以上代码可以看到，在 TensorFlow 中只需要在 BasicLSTMCell 的基础上再封装一层 MultiRNNCell 就可以非常容易地实现深层循环神经网络了。

8.3.2 循环神经网络的 dropout

6.4 节介绍过在卷积神经网络上使用 dropout 的方法。通过 dropout，可以让卷积神经网络更加健壮（robust）^①。类似的，在循环神经网络中使用 dropout 也有同样的功能。而且，类似卷积神经网络只在最后的全连接层中使用 dropout，循环神经网络一般只在不同层循环体结构之间使用 dropout，而不在同一层的循环体结构之间使用。也就是说从时刻 $t-1$ 传递到时刻 t 时，循环神经网络不会进行状态的 dropout；而在同一个时刻 t 中，不同层循环体之间会使用 dropout。

如图 8-9 展示了循环神经网络使用 dropout 的示意图。假设要从 $t-2$ 时刻的输入 x_{t-2} 传递到 $t+1$ 时刻的输出 y_{t+1} ，那么 x_{t-2} 将首先传入第一层循环体结构，这个过程会使用 dropout。但是从 $t-2$ 时刻的第一层循环体结构传递到第一层的 $t-1$ 、 t 、 $t+1$ 时刻不会使用 dropout。在 $t+1$ 时刻的第一层循环体结构传递到同一时刻内更高层的循环体结构时，会再次使用 dropout。

① Zaremba W, Sutskever I, Vinyals O. *Recurrent Neural Network Regularization*[J]. Eprint Arxiv, 2014.




图 8-9 深层循环神经网络使用 dropout 示意图

(图中实线箭头表示不使用 dropout，虚线箭头表示使用 dropout)

在 Tensorflow 中，使用 `tf.nn.rnn_cell.DropoutWrapper` 类可以很容易实现 dropout 功能。以下代码展示了如何在 TensorFlow 中实现带 dropout 的循环神经网络。

```
# 定义 LSTM 结构。
lstm = rnn_cell.BasicLSTMCell(lstm_size)

# 使用 DropoutWrapper 类来实现 dropout 功能。该类通过两个参数来控制 dropout 的概率，
# 一个参数为 input_keep_prob，它可以用来控制输入的 dropout 概率①；另一个为
# output_keep_prob，它可以用来控制输出的 dropout 概率。
dropout_lstm = tf.nn.rnn_cell.DropoutWrapper(lstm, output_keep_prob=0.5)

# 在使用了 dropout 的基础上定义
stacked_lstm = rnn_cell.MultiRNNCell([dropout_lstm] * number_of_layers)

# 和 8.3.1 小节中深层循环网络样例程序类似，运行前向传播过程。
```

8.4 循环神经网络样例应用

在以上几节中已经介绍了不同循环神经网络的网络结构，并给出了具体的 TensorFlow 程序来实现这些循环神经网络的前向传播过程。这一节将给出两个具体的循环神经网络应用样例——自然语言建模和时序预测。在 8.4.1 小节中将简单介绍什么是自然语言建模，并

① 注意这里定义的实际上是节点被保留的概率。如果给出的数字为 0.9，那么只有 10% 的节点会被 dropout。

通过 TensorFlow 实现在 Penn TreeBank (PTB) 数据集上的自然语言模型。在 8.4.2 小节中将简单介绍 TensorFlow 的高层封装工具 TFLearn, 并通过 TFLearn 实现对函数 $\sin x$ 取值的预测。

8.4.1 自然语言建模

简单地说, 语言模型的目的是为了计算一个句子的出现概率。在这里把句子看成是单词的序列, 于是语言模型需要计算的就是 $p(w_1, w_2, w_3, \dots, w_m)$ 。利用语言模型, 可以确定哪个单词序列出现的可能性更大, 或者给定若干个单词, 可以预测下一个最可能出现的词语。举个音字转换的例子, 假设输入的拼音串为 “xianzaiquna”, 它的输出可以是 “西安在去哪”, 也可以是 “现在去哪”。根据语言常识可以知道, 转换成第二个的概率更高。语言模型就可以得到后者的概率大于前者, 因此在大多数情况下转换成后者比较合理。

那么如何计算一个句子的概率呢? 首先一个句子可被看成是一个单词序列:

$$S=(w_1, w_2, w_3, w_4, w_5, \dots, w_m)$$

其中 m 为句子的长度。那么, 它的概率可以表示为:

$$\begin{aligned} p(S) &= p(w_1, w_2, w_3, w_4, w_5, \dots, w_m) \\ &= p(w_1) p(w_2 | w_1) p(w_3 | w_1, w_2) \dots p(w_m | w_1, w_2, \dots, w_{m-1}) \end{aligned}$$

要计算一个句子出现的概率, 就需要知道上面公式中等式右边中每一项的取值。等式右边的每一项都是语言模型中的一个参数。一般来说, 任何一门语言的词汇量都很大, 词汇的组合更不计其数。为了估计这些参数的取值, 常见的方法有 **n-gram** 方法、决策树、最大熵模型、条件随机场、神经网络语言模型, 等等。本小节将先以其中最简单的 **n-gram** 模型来介绍语言模型问题以及评价模型优劣的标准。**n-gram** 模型有一个有限历史假设: 当前单词的出现概率仅仅与前面的 $n-1$ 个单词相关。因此以上公式可以近似为:

$$p(S) = p(w_1, w_2, w_3, \dots, w_m) = \prod_i^m p(w_i | w_{i-n+1}, \dots, w_{i-1})$$

n-gram 模型里的 n 指的是当前单词依赖它前面的单词的个数。通常 n 可以取 1、2、3, 这时 **n-gram** 模型分别称为 **unigram**、**bigram** 和 **trigram** 语言模型。**n-gram** 模型中需要估计的参数为条件概率 $p(w_i | w_{i-n+1}, \dots, w_{i-1})$ 。假设某种语言的单词表大小为 k , 那么 **n-gram** 模型需要估计的不同参数数量为 k^n 。当 n 越大时, **n-gram** 模型理论上越准确, 但也越复杂, 需要的计算量和训练语料数据量也就越大。因此, 最常用的是 **bigram**, 其次是 **unigram** 和 **trigram**。 $n \geq 4$ 的情况非常少。**n-gram** 模型的参数一般采用最大似然估计 (maximum likelihood estimation, MLE) 的方法计算:

$$p(w_i | w_{i-n+1}, \dots, w_{i-1}) = \frac{C(w_{i-n+1}, \dots, w_{i-1}, w_i)}{C(w_{i-n+1}, \dots, w_{i-1})}$$

其中 $C(X)$ 表示单词序列 X 在训练语料中出现的次数。训练语料的规模越大，参数估计的结果越可靠。但即使训练数据的规模非常大时，还是会有很多单词序列在训练语料中没有出现过，这就会导致很多参数为 0。举个例子来说，IBM 使用了 366M 英语语料训练 trigram，发现 14.7% 的 trigram 和 2.2% 的 bigram 在训练中没有出现。为了避免因为乘以 0 而导致整个概率为 0，使用最大似然估计方法时都需要加入平滑避免参数取值为 0。使用 n -gram 建立语言模型的细节不再赘述，感兴趣的读者可以看考书籍 *Information Retrieval: Implementing and Evaluating Search Engines*^①。

语言模型效果好坏的常用评价指标是复杂度 (perplexity)。简单来说，perplexity 值刻画的就是通过某一个语言模型估计的一句话出现的概率。比如当已经知道 $(w_1, w_2, w_3, \dots, w_m)$ 这句话出现在语料库之中，那么通过语言模型计算得到的这句话的概率越高越好，也就是 perplexity 值越小越好。计算 perplexity 值的公式如下：

$$\begin{aligned} \text{Perplexity}(S) &= p(w_1, w_2, w_3, \dots, w_m)^{-\frac{1}{m}} \\ &= \sqrt[m]{\frac{1}{p(w_1, w_2, w_3, \dots, w_m)}} \\ &= \sqrt[m]{\prod_{i=1}^m \frac{1}{p(w_i | w_1, w_2, \dots, w_{i-1})}} \end{aligned}$$

复杂度 perplexity 表示的概念其实是平均分支系数 (average branch factor)，即模型预测下一个词时的平均可选择数量。例如，考虑一个由 0~9 这 10 个数字随机组成的长度为 m 的序列。由于这 10 个数字出现的概率是随机的，所以每个数字出现的概率是 $\frac{1}{10}$ 。因此，在任意时刻，模型都有 10 个等概率的候选答案可以选择，于是 perplexity 就是 10 (有 10 个合理的答案)。perplexity 的计算过程如下：

$$\text{Perplexity}(S) = \sqrt[m]{\prod_{i=1}^m \frac{1}{\frac{1}{10}}} = 10$$

因此，如果一个语言模型的 perplexity 是 89，就表示，平均情况下，模型预测下一个词时，有 89 个词等可能地可以作为下一个词的合理选择。另一种常用的 perplexity 表达形式如下：

①Bttcher S, Clarke C L A, Cormack G V. *Information Retrieval: Implementing and Evaluating Search Engines*[M]. The MIT Press, 2016.

$$\log(\text{perplexity}(S)) = -\sum_{m} p(w_i | w_1, w_2, \dots, w_{i-1})$$

相比乘积开根号的方式，使用加法的形式可以加速计算，这也有效地避免了概率为 0 时导致整个计算结果为 0 的问题。

除了 n-gram 模型，循环神经网络也可以用来对自然语言建模。考虑如图 8-10 所示的循环神经网络，每个时刻的输入为一个句子中的单词，而每个时刻的输出为一个概率分布，表示句子中下一个位置为不同单词的概率。通过这种方式，对于给定的句子，就可以通过循环神经网络的前向传播过程计算出 $p(w_i | w_1, \dots, w_{i-1})$ 。比如在图 8-10 中，在第一个时刻输入的单词为“大海”，而输出为 $p(x|“大海”)$ 。也就是在知道第一个词为“大海”后，其他不同单词出现在下一个位置的概率。比如从图 8-10 中可以看出， $p(“的”|“大海”)=0.8$ ，也就是说“大海”之后的单词为“的”的概率为 0.8。

类似的，通过循环神经网络可以求得概率 $p(x|“大海”, “的”)$ 、 $p(x|“大海”, “的”, “颜色”)$ 、 $p(x|“大海”, “的”, “颜色”, “是”)$ 。于是也可以求得整个句子“大海的颜色是蓝色”的概率，从而计算出这句话的 perplexity 值。在本小节后面的篇幅中将给出具体的 TensorFlow 代码来实现通过循环神经网络对自然语言建模。

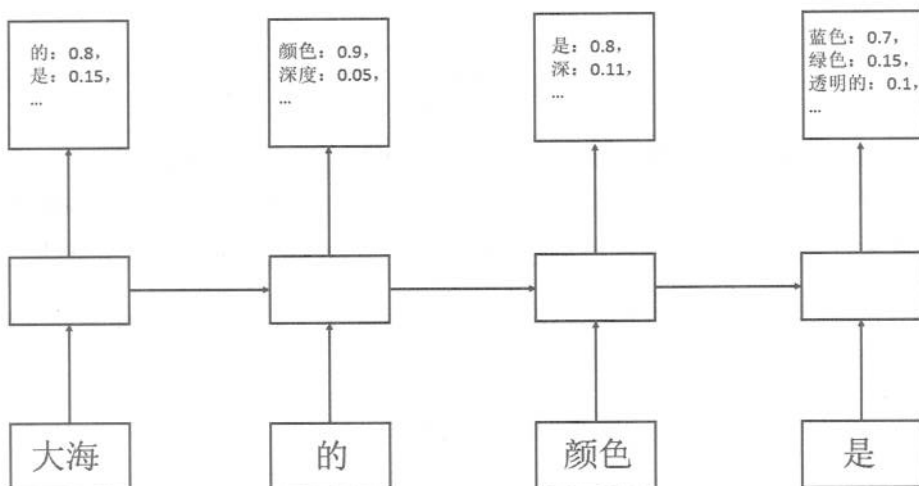


图 8-10 使用循环神经网络实现自然语言建模示意图

PTB 文本数据集介绍

PTB (Penn Treebank Dataset) 文本数据集是语言模型学习中目前最广泛使用的数据集。本小节将在 PTB 数据集上使用循环神经网络实现语言模型。在给出语言模型代码之前将先简单介绍 PTB 数据集的格式以及 TensorFlow 对于 PTB 数据集的支持。首先，需要下载来

源于 Tomas Mikolov 网站上的 PTB 数据。数据的下载地址为：

```
http://www.fit.vutbr.cz/~imikolov/rnnlm/simple-examples.tgz
```

将下载下来的文件解压之后可以得到如下文件夹列表

```
1-train/
2-nbest-rescore/
3-combination/
4-data-generation/
5-one-iter/
6-recovery-during-training/
7-dynamic-evaluation/
8-direct/
9-char-based-lm/
data/
models/
rnnlm-0.2b/
```

本书只需要关心 data 文件夹下的数据，对于其他文件不再一一介绍，感兴趣的读者可以自行参考 README 文件。在 data 文件夹下总共有 7 个文件，但本书中将只会用到以下三个文件：

```
ptb.test.txt    # 测试集数据文件
ptb.train.txt   # 训练集数据文件
ptb.valid.txt   # 验证集数据文件
```

这三个数据文件中的数据已经经过了预处理，包含了 10000 个不同的词语和语句结束标记符（在文本中就是换行符）以及标记稀有词语的特殊符号<unk>。下面展示了训练数据中的一行：

```
mr. <unk> is chairman of <unk> n.v. the dutch publishing group
```

为了让使用 PTB 数据集更加方便，TensorFlow 提供了两个函数来帮助实现数据的预处理。首先，TensorFlow 提供了 ptb_raw_data 函数来读取 PTB 的原始数据，并将原始数据中的单词转化为单词 ID。以下代码展示了如何使用这个函数。

```
from tensorflow.models.rnn.ptb import reader

# 存放原始数据的路径。
DATA_PATH = "/path/to/ptb/data"
train_data, valid_data, test_data, _ = reader.ptb_raw_data(DATA_PATH)
# 读取数据原始数据。
print len(train_data)
```

```
print train_data[:100]

'''
运行以上程序可以得到输出：
929589
[9970, 9971, 9972, 9974, 9975, 9976, 9980, 9981, 9982, 9983, 9984, 9986, 9987,
9988, 9989, 9991, 9992, 9993, 9994, 9995, 9996, 9997, 9998, 9999, 2, 9256,
1, 3, 72, 393, 33, 2133, 0, 146, 19, 6, 9207, 276, 407, 3, 2, 23, 1, 13, 141,
4, 1, 5465, 0, 3081, 1596, 96, 2, 7682, 1, 3, 72, 393, 8, 337, 141, 4, 2477,
657, 2170, 955, 24, 521, 6, 9207, 276, 4, 39, 303, 438, 3684, 2, 6, 942, 4,
3150, 496, 263, 5, 138, 6092, 4241, 6036, 30, 988, 6, 241, 760, 4, 1015, 2786,
211, 6, 96, 4]
'''
```

从输出中可以看出训练数据中总共包含了 929589 个单词，而这些单词被组成了一个非常长的序列。这个序列通过特殊的标识符给出了每句话结束的位置。在这个数据集中，句子结束的标识符 ID 为 2。

在 8.1 节中介绍过，虽然循环神经网络可以接受任意长度的序列，但是在训练时需要将序列按照某个固定的长度来截断。为了实现截断并将数据组织成 batch，TensorFlow 提供了 `ptb_iterator` 函数。以下代码展示了如何使用 `ptb_iterator` 函数。

```
from tensorflow.models.rnn.ptb import reader

# 类似地读取数据原始数据。
DATA_PATH = "/path/to/ptb/data"
train_data, valid_data, test_data, _ = reader.ptb_raw_data(DATA_PATH)

# 将训练数据组织成 batch 大小为 4、截断长度为 5 的数据组。
result = reader.ptb_iterator(train_data, 4, 5)
# 读取第一个 batch 中的数据，其中包括每个时刻的输入和对应的正确输出。
x, y = result.next()
print "X:", x
print "y:", y

'''
运行以上程序可以得到输出：
X: [[9970 9971 9972 9974 9975]
[ 332 7147 328 1452 8595]
[1969 0 98 89 2254]
[ 3 3 2 14 24]]
y: [[9971 9972 9974 9975 9976]
```

```

[7147 328 1452 8595 59]
[ 0 98 89 2254 0]
[ 3 2 14 24 198]]
...

```

图 8-11 展示了 `ptb_iterator` 函数实现的功能。`ptb_iterator` 函数会将一个长序列划分为 `batch_size` 段，其中 `batch_size` 为一个 batch 的大小。每次调用 `ptb_iterator` 时，该函数会从每一段中读取长度为 `num_step` 的子序列，其中 `num_step` 为截断的长度。从上面代码的输出可以看到，在第一个 batch 的第一行中，前面 5 个单词的 ID 和整个训练数据中前 5 个单词的 ID 是对应的。`ptb_iterator` 在生成 batch 时会自动生成每个 batch 对应的正确答案，这个对于每一个单词，它对应的正确答案就是该单词的后面一个单词。

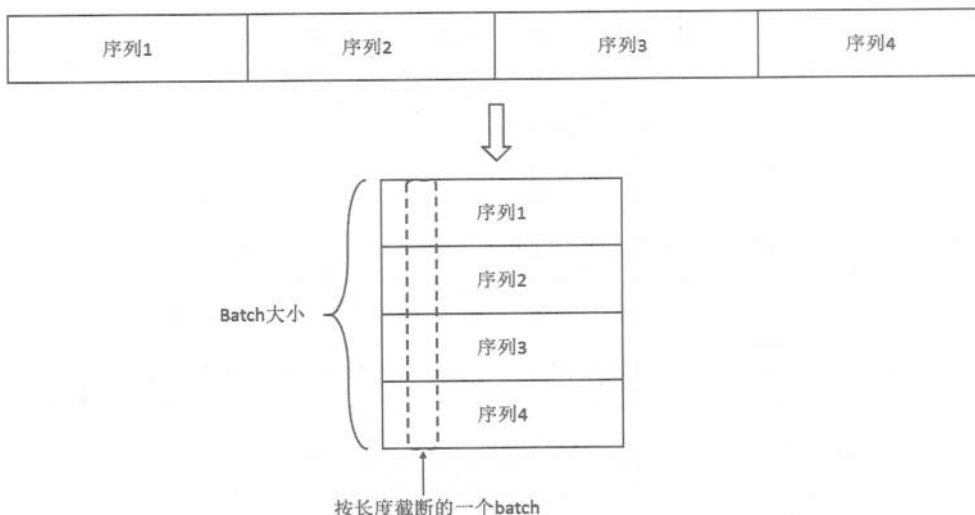


图 8-11 将一个长序列分成 batch 并截断的操作示意图

使用循环神经网络实现语言模型

在介绍了语言模型的理论和使用到的数据集之后，下面给出了一个完成的 TensorFlow 样例程序来通过循环神经网络实现语言模型。

```

# -*- coding: utf-8 -*-
import numpy as np

import tensorflow as tf
from tensorflow.models.rnn.ptb import reader

DATA_PATH = "/path/to/ptb/data"    # 数据存放的路径。
HIDDEN_SIZE = 200                  # 隐藏层规模。

```

```
NUM_LAYERS = 2                                # 深层神经网络中 LSTM 结构的层数。
VOCAB_SIZE = 10000                            # 词典规模，加上语句结束标识符和稀有
                                                # 单词标识符总共一万个单词。

LEARNING_RATE = 1.0                          # 学习速率。
TRAIN_BATCH_SIZE = 20                        # 训练数据 batch 的大小。
TRAIN_NUM_STEP = 35                          # 训练数据截断长度。

# 在测试时不需要使用截断，所以可以将测试数据看成一个超长的序列。
EVAL_BATCH_SIZE = 1                          # 测试数据 batch 的大小。
EVAL_NUM_STEP = 1                            # 测试数据截断长度。
NUM_EPOCH = 2                                # 使用训练数据的轮数。
KEEP_PROB = 0.5                              # 节点不被 dropout 的概率。
MAX_GRAD_NORM = 5                            # 用于控制梯度膨胀的参数。

# 通过一个 PTBModel 类来描述模型，这样方便维护循环神经网络中的状态。
class PTBModel(object):
    def __init__(self, is_training, batch_size, num_steps):
        # 记录使用的 batch 大小和截断长度。
        self.batch_size = batch_size
        self.num_steps = num_steps

        # 定义输入层。可以看到输入层的维度为 batch_size × num_steps，这和
        # ptb_iterator 函数输出的训练数据 batch 是一致的。
        self.input_data = tf.placeholder(tf.int32, [batch_size, num_steps])

        # 定义预期输出。它的维度和 ptb_iterator 函数输出的正确答案维度也是一样的。
        self.targets = tf.placeholder(tf.int32, [batch_size, num_steps])

        # 定义使用 LSTM 结构为循环体结构且使用 dropout 的深层循环神经网络。
        lstm_cell = tf.nn.rnn_cell.BasicLSTMCell(HIDDEN_SIZE)
        if is_training:
            lstm_cell = tf.nn.rnn_cell.DropoutWrapper(
                lstm_cell, output_keep_prob=KEEP_PROB)
        cell = tf.nn.rnn_cell.MultiRNNCell([lstm_cell] * NUM_LAYERS)

        # 初始化最初的状态，也就是全零的向量。
        self.initial_state = cell.zero_state(batch_size, tf.float32)
        # 将单词 ID 转换为单词向量。因为总共有 VOCAB_SIZE 个单词，每个单词向量的维度
        # 为 HIDDEN_SIZE，所以 embedding 参数的维度为 VOCAB_SIZE × HIDDEN_SIZE①。
        embedding = tf.get_variable("embedding", [VOCAB_SIZE, HIDDEN_SIZE])

        # 将原本 batch_size × num_steps 个单词 ID 转化为单词向量，转化后的输入层维度
```

① 关于更多关于使用 TensorFlow 实现单词向量的资料可以参考 TensorFlow 官方网站：<https://www.tensorflow.org/tutorials/word2vec/>。

```

# 为 batch_size × num_steps × HIDDEN_SIZE。
inputs = tf.nn.embedding_lookup(embedding, self.input_data)

# 只在训练时使用 dropout。
if is_training: inputs = tf.nn.dropout(inputs, KEEP_PROB)

# 定义输出列表。在这里先将不同时刻 LSTM 结构的输出收集起来，再通过一个全连接
# 层得到最终的输出。
outputs = []
# state 存储不同 batch 中 LSTM 的状态，将其初始化为 0。
state = self.initial_state
with tf.variable_scope("RNN"):
    for time_step in range(num_steps):
        if time_step > 0: tf.get_variable_scope().reuse_variables()
        # 从输入数据中获取当前时刻的输入并传入 LSTM 结构。
        cell_output, state = cell(inputs[:, time_step, :], state)
        # 将当前输出加入输出队列。
        outputs.append(cell_output)

# 把输出队列展开成 [batch, hidden_size*num_steps] 的形状，然后再
# reshape 成 [batch*numsteps, hidden_size] 的形状。
output = tf.reshape(tf.concat(1, outputs), [-1, HIDDEN_SIZE])

# 将从 LSTM 中得到的输出再经过一个全链接层得到最后的预测结果，最终的预测结果在
# 每一个时刻上都是一个长度为 VOCAB_SIZE 的数组，经过 softmax 层之后表示下一个
# 位置是不同单词的概率。
weight = tf.get_variable("weight", [HIDDEN_SIZE, VOCAB_SIZE])
bias = tf.get_variable("bias", [VOCAB_SIZE])
logits = tf.matmul(output, weight) + bias

# 定义交叉熵损失函数。TensorFlow 提供了 sequence_loss_by_example 函数来计
# 算一个序列的交叉熵的和。
loss = tf.nn.seq2seq.sequence_loss_by_example(
    [logits], # 预测的结果。
    [tf.reshape(self.targets, [-1])], # 期待的正确答案，这里将
    # [batch_size, num_steps]
    # 二维数组压缩成一维数组。
    # 损失的权重。在这里所有的权重都为 1，也就是说不同 batch 和不同时刻
    # 的重要程度是一样的。
    [tf.ones([batch_size * num_steps], dtype=tf.float32)])

# 计算得到每个 batch 的平均损失。
self.cost = tf.reduce_sum(loss) / batch_size
self.final_state = state

# 只在训练模型时定义反向传播操作。
if not is_training: return

```



```

trainable_variables = tf.trainable_variables()
# 通过 clip_by_global_norm 函数控制梯度的大小, 避免梯度膨胀的问题。
grads, _ = tf.clip_by_global_norm(
    tf.gradients(self.cost, trainable_variables), MAX_GRAD_NORM)

# 定义优化方法。
optimizer = tf.train.GradientDescentOptimizer(LEARNING_RATE)
# 定义训练步骤。
self.train_op = optimizer.apply_gradients(
    zip(grads, trainable_variables))

# 使用给定的模型 model 在数据 data 上运行 train_op 并返回在全部数据上的 perplexity 值。
def run_epoch(session, model, data, train_op, output_log):
    # 计算 perplexity 的辅助变量。
    total_costs = 0.0
    iters = 0
    state = session.run(model.initial_state)
    # 使用当前数据训练或者测试模型。
    for step, (x, y) in enumerate(
        reader.ptb_iterator(data, model.batch_size, model.num_steps)):
        # 在当前 batch 上运行 train_op 并计算损失值。交叉熵损失函数计算的就是下一个单
        # 词为给定单词的概率。
        cost, state, _ = session.run(
            [model.cost, model.final_state, train_op],
            {model.input_data: x, model.targets: y,
             model.initial_state: state})
        # 将不同时刻、不同 batch 的概率加起来就可以得到第二个 perplexity 公式等号右
        # 边的部分, 再将这个和做指数运算就可以得到 perplexity 值。
        total_costs += cost
        iters += model.num_steps

    # 只有在训练时输出日志。
    if output_log and step % 100 == 0:
        print("After %d steps, perplexity is %.3f" % (
            step, np.exp(total_costs / iters)))

    # 返回给定模型在给定数据上的 perplexity 值。
    return np.exp(total_costs / iters)

def main(_):
    # 获取原始数据。
    train_data, valid_data, test_data, _ = reader.ptb_raw_data(DATA_PATH)

    # 定义初始化函数。
    initializer = tf.random_uniform_initializer(-0.05, 0.05)
    # 定义训练用的循环神经网络模型。

```

```

with tf.variable_scope("language_model",
                       reuse=None, initializer=initializer):
    train_model = PTBModel(True, TRAIN_BATCH_SIZE, TRAIN_NUM_STEP)

# 定义评测用的循环神经网络模型。
with tf.variable_scope("language_model",
                       reuse=True, initializer=initializer):
    eval_model = PTBModel(False, EVAL_BATCH_SIZE, EVAL_NUM_STEP)

with tf.Session() as session:
    tf.initialize_all_variables().run()

    # 使用训练数据训练模型。
    for i in range(NUM_EPOCH):
        print("In iteration: %d" % (i + 1))
        # 在所有训练数据上训练循环神经网络模型。
        run_epoch(session, train_model,
                  train_data, train_model.train_op, True)

        # 使用验证数据评测模型效果。
        valid_perplexity = run_epoch(
            session, eval_model, valid_data, tf.no_op(), False)
        print("Epoch: %d Validation Perplexity: %.3f" % (
            i + 1, valid_perplexity))

    # 最后使用测试数据测试模型效果。
    test_perplexity = run_epoch(
        session, eval_model, test_data, tf.no_op(), False)
    print("Test Perplexity: %.3f" % test_perplexity)

if __name__ == "__main__":
    tf.app.run()

```

运行以上程序可以得到类似如下的输出^①:

```

In iteration: 1
After 0 steps, perplexity is 10003.783
After 100 steps, perplexity is 1404.742
After 200 steps, perplexity is 1061.458
After 300 steps, perplexity is 891.044
After 400 steps, perplexity is 782.037

```

① 在 TensorFlow 0.9.0 下运行会提示:“WARNING:tensorflow:<tensorflow.python.ops.rnn_cell.BasicLSTMCell object at 0x7fcb4f3ae150>: Using a concatenated state is slower and will soon be deprecated. Use state_is_tuple=True.” 这不会影响运行。但是 TensorFlow 0.9.0 对 state_is_tupe=True 不支持, 所以书中没有设置, 在 TensorFlow 更高的版本中可以将 state_is_tuple 参数设置为 True。

```
...
After 1100 steps, perplexity is 228.711
After 1200 steps, perplexity is 226.093
After 1300 steps, perplexity is 223.214
Epoch: 2 Validation Perplexity: 183.443
Test Perplexity: 179.420
```

从输出可以看出，在迭代开始时 `perplexity` 值为 10003.783，这基本相当于从一万个单词中随机选择下一个单词。而在训练结束后，在训练数据上的 `perplexity` 值降低到了 179.420。这表明通过训练过程，将选择下一个单词的范围从一万个减小到了大约 180 个。通过调整 LSTM 隐藏层的节点个数和大小以及训练迭代的轮数还可以将 `perplexity` 值降到更低。

8.4.2 时间序列预测

本小节将介绍如何利用循环神经网络来预测正弦（sin）函数^①，图 8-12 给出了 sin 函数的函数图像。在给出具体的 TensorFlow 代码之前，本小节将先介绍另外一个对 TensorFlow 的高层封装——TFLearn^②。和第 6 章中介绍的 TensorFlow-Slim 类似，通过使用 TFLearn 可以让 TensorFlow 代码效率进一步提高。




图 8-12 sin 函数曲线

① 本小节部分内容参考自：<http://mourafiq.com/2016/05/15/predicting-sequences-using-rnn-in-tensorflow.html>

② TFLearn 又名 skflow，它们是同一套系统。

使用 TFLearn 自定义模型

TensorFlow 的另外一个高层封装 TFLearn(集成在 `tf.contrib.learn` 里)对训练 TensorFlow 模型进行了一些封装,使其更便于使用。本小节将通过 iris 数据集简单介绍如何使用 TFLearn 实现分类问题。iris 数据集需要通过 4 个特征(feature)来分辨三种类型的植物。iris 数据集中总共包含了 150 个样本^①。以下程序展示了如何通过 TFLearn 快速的解决 iris 分类问题。

```
# -*- coding: utf-8 -*-

# 为了方便数据处理,本程序使用了 sklearn 工具包,关于这个工具包更多的信息可以参考
# http://scikit-learn.org/。
from sklearn import cross_validation
from sklearn import datasets
from sklearn import metrics
import tensorflow as tf

# 导入 TFLearn。
learn = tf.contrib.learn

# 自定义模型,对于给定的输入数据(features)以及其对应的正确答案(target),返回在这
# 些输入上的预测值、损失值以及训练步骤。
def my_model(features, target):
    # 将预测的目标转换为 one-hot 编码的形式,因为共有三个类别,所以向量长度为 3。经过转
    # 化后,第一个类别表示为(1,0,0),第二个为(0,1,0),第三个为(0,0,1)。
    target = tf.one_hot(target, 3, 1, 0)

    # 定义模型以及其在给定数据上的损失函数。TFLearn 通过 logistic_regression 封装了
    # 一个单层全连接神经网络。
    logits, loss = learn.models.logistic_regression(features, target)

    # 创建模型的优化器,并得到优化步骤。
    train_op = tf.contrib.layers.optimize_loss(
        loss,                                     # 损失函数
        tf.contrib.framework.get_global_step(), # 获取训练步数并在训练时更新
        optimizer='Adagrad',                    # 定义优化器
        learning_rate=0.1)                      # 定义学习率

    # 返回在给定数据上的预测结果、损失值以及优化步骤。
    return tf.argmax(logits, 1), loss, train_op

# 加载 iris 数据集,并划分为训练集合和测试集合。
iris = datasets.load_iris()
x_train, x_test, y_train, y_test = cross_validation.train_test_split(
```

① 更多关于 iris 数据集的信息可以参考: <http://archive.ics.uci.edu/ml/datasets/Iris>。

```
iris.data, iris.target, test_size=0.2, random_state=0)

# 对自定义的模型进行封装。
classifier = learn.Estimator(model_fn=my_model)

# 使用封装好的模型和训练数据执行 100 轮迭代。
classifier.fit(x_train, y_train, steps=100)

# 使用训练好的模型进行结果预测。
y_predicted = classifier.predict(x_test)

# 计算模型的准确度。
score = metrics.accuracy_score(y_test, y_predicted)
print('Accuracy: %.2f%%' % (score * 100))

'''
运行以上程序可以得到输出:
Accuracy: 90.00%
'''
```

通过以上程序可以看出 TFLearn 既封装了一些常用的神经网络结构，又省去了模型训练的部分，这让 TensorFlow 的程序可以变得更加简短。

预测正弦函数

通过 TFLearn，下面的篇幅将给出具体的 TensorFlow 程序来实现预测正弦函数 \sin 。因为标准的循环神经网络模型预测的是离散的数值，所以在程序中需要将连续的 \sin 函数曲线离散化。所谓离散化就是在一个给定的区间 $[0, \text{MAX}]$ 内，通过有限个采样点模拟一个连续的曲线。比如在以下程序中每隔 `SAMPLE_ITERVAL` 对 \sin 函数进行一次采样，采样得到的序列就是 \sin 函数离散化之后的结果。以下程序为预测离散化之后的 \sin 函数。

```
# -*- coding: utf-8 -*-

import numpy as np
import tensorflow as tf

# 加载 matplotlib 工具包，使用该工具可以对预测的 sin 函数曲线进行绘图。
import matplotlib as mpl
mpl.use('Agg')
from matplotlib import pyplot as plt

learn = tf.contrib.learn

HIDDEN_SIZE = 30 # LSTM 中隐藏节点的个数。
NUM_LAYERS = 2 # LSTM 的层数。
```

```

TIMESTEPS = 10                                # 循环神经网络的截断长度。
TRAINING_STEPS = 10000                         # 训练轮数。
BATCH_SIZE = 32                               # batch 大小。

TRAINING_EXAMPLES = 10000                     # 训练数据个数。
TESTING_EXAMPLES = 1000                       # 测试数据个数。
SAMPLE_GAP = 0.01                             # 采样间隔。

def generate_data(seq):
    X = []
    y = []
    # 序列的第 i 项和后面的 TIMESTEPS-1 项合在一起作为输入；第 i + TIMESTEPS 项作为输出。即用 sin 函数前面的 TIMESTEPS 个点的信息，预测第 i + TIMESTEPS 个点的函数值。
    for i in range(len(seq) - TIMESTEPS - 1):
        X.append([seq[i: i + TIMESTEPS]])
        y.append([seq[i + TIMESTEPS]])
    return np.array(X, dtype=np.float32), np.array(y, dtype=np.float32)

def lstm_model(X, y):
    # 使用多层的 lstm 结构。
    lstm_cell = tf.nn.rnn_cell.BasicLSTMCell(HIDDEN_SIZE)
    cell = tf.nn.rnn_cell.MultiRNNCell([lstm_cell] * NUM_LAYERS)
    x_ = tf.unpack(X, axis=1)①

    # 使用 TensorFlow 接口将多层的 LSTM 结构连接成 RNN 网络并计算其前向传播结果。
    output, _ = tf.nn.rnn(cell, x_, dtype=tf.float32)
    # 在本问题中只关注最后一个时刻的输出结果，该结果为下一时刻的预测值。
    output = output[-1]

    # 对 LSTM 网络的输出再做加一层全链接层并计算损失。注意这里默认的损失为平均平方差损失函数。
    prediction, loss = learn.models.linear_regression(output, y)

    # 创建模型优化器并得到优化步骤。
    train_op = tf.contrib.layers.optimize_loss(
        loss, tf.contrib.framework.get_global_step(),
        optimizer="Adagrad", learning_rate=0.1)

    return prediction, loss, train_op

# 建立深层循环网络模型。

```

① 此处要求 TensorFlow0.10.0 及以上版本。


```

regressor = learn.Estimator(model_fn=lstm_model)

# 用正弦函数生成训练和测试数据集。
# numpy.linspace 函数可以创建一个等差序列的数组，它常用的参数有三个参数，第一个参数
# 表示起始值，第二个参数表示终止值，第三个参数表示数列的长度。例如，linspace(1,10,10)
# 产生的数组是 array([1,2,3,4,5,6,7,8,9,10])。
test_start = TRAINING_EXAMPLES * SAMPLE_GAP
test_end = (TRAINING_EXAMPLES + TESTING_EXAMPLES) * SAMPLE_GAP
train_X, train_y = generate_data(np.sin(np.linspace(
    0, test_start, TRAINING_EXAMPLES, dtype=np.float32)))
test_X, test_y = generate_data(np.sin(np.linspace(
    test_start, test_end, TESTING_EXAMPLES, dtype=np.float32)))

# 调用 fit 函数训练模型。
regressor.fit(train_X, train_y, batch_size=BATCH_SIZE,
              steps=TRAINING_STEPS)

# 使用训练好的模型对测试数据进行预测。
predicted = [[pred] for pred in regressor.predict(test_X)]
# 计算 rmse 作为评价指标。
rmse = np.sqrt(((predicted - test_y) ** 2).mean(axis=0))
print ("Mean Square Error is: %f" % rmse[0])

'''
运行以上程序可以得到输出：①
Mean Square Error is: 0.002183
从输出可以看出通过循环神经网络可以非常精确的预测正弦函数 sin 的取值。
'''

#对预测的 sin 函数曲线进行绘图，并存储到运行目录下的 sin.png
fig = plt.figure()
plot_predicted = plt.plot(predicted, label='predicted')
plot_test = plt.plot(test_y, label='real_sin')
plt.legend([plot_predicted, plot_test], ['predicted', 'real_sin'])
# 得到的结果如图 8-21 所示。
fig.savefig('sin.png')

```

从图 8-13 中可以看出，预测得到的结果和真实的 sin 函数几乎是重合的。也就是说通过循环神经网络可以非常好地预测 sin 函数的取值。

① 运行该程序可能会因为 TFLearn 的版本而得到一些 warning，但这些 warning 不会影响程序的正常运行。




图 8-13 通过循环神经网络预测 sin 函数得到的结果

小结

本章详细介绍了循环神经网络的整体架构，并介绍了循环神经网络中最常用的 LSTM 结构。在本章中也给出了两个具体的样例来介绍如何将循环神经网络应用于实际问题之中。首先，在本章的 8.1 节中讲解了什么是循环神经网络。在这一节中介绍了循环神经网络的整体结构，并给出了一个具体的样例来说明循环神经网络是如何工作的。接着，在 8.2 节中介绍循环神经网络中使用的最为广泛的 LSTM 结构，大致介绍了 LSTM 结构的主要成分，并给出了具体的 TensorFlow 样例程序来实现使用了 LSTM 结构的循环神经网络。然后，在 8.3 节中介绍了 LSTM 结构的一些主流变种。最后，在 8.4 节中给出了使用循环神经网络解决具体问题的两个案例。在 8.4.1 小节中介绍了如何使用循环神经网络实现自然语言模型；在 8.4.2 小节介绍了通过 TensorFlow 的高层封装 TFLearn 实现时序预测问题。

第 9 章 TensorBoard 可视化

前面的章节已经介绍了如何使用 TensorFlow 实现常用的神经网络结构。在将这些神经网络用于实际问题之前，需要先优化神经网络中的参数。这就是训练神经网络的过程。训练神经网络十分复杂，有时需要几天甚至几周的时间。为了更好的管理、调试和优化神经网络的训练过程，TensorFlow 提供了一个可视化工具 TensorBoard。TensorBoard 可以有效地展示 TensorFlow 在运行过程中的计算图、各种指标随着时间的变化趋势以及训练中使用到的图像等信息。

本章将详细介绍 TensorBoard 的使用方法。首先，9.1 节将介绍 TensorBoard 的基础知识，并通过 TensorBoard 来可视化一个简单的 TensorFlow 样例程序。在这一节中将介绍如何启动 TensorBoard，并大致讲解 TensorBoard 提供的几类可视化信息。然后，9.2 节将介绍通过 TensorBoard 得到的 TensorFlow 计算图的可视化结果。TensorFlow 计算图保存了 TensorFlow 程序计算过程的所有信息。因为 TensorFlow 计算图中的信息含量较多，所以 TensorBoard 设计了一套交互过程来更加清晰地呈现这些信息。在这一节中将详细介绍 TensorBoard 的交互流程以及可视化结果中提供的信息。最后，9.3 节将详细讲解如何使用 TensorBoard 对训练过程进行监控，以及如何通过 TensorFlow 指定需要可视化的指标。在这一节中给出了完整的样例程序介绍如何得到可视化结果。

9.1 TensorBoard 简介

TensorBoard 是 TensorFlow 的可视化工具，它可以通过 TensorFlow 程序运行过程中输出的日志文件可视化 TensorFlow 程序的运行状态。TensorBoard 和 TensorFlow 程序跑在不同的进程中，TensorBoard 会自动读取最新的 TensorFlow 日志文件，并呈现当前 TensorFlow 程序运行的最新状态。以下代码展示了一个简单的 TensorFlow 程序，在这个程序中完成了 TensorBoard 日志输出的功能。

```
import tensorflow as tf

# 定义一个简单的计算图，实现向量加法的操作。
input1 = tf.constant([1.0, 2.0, 3.0], name="input1")
input2 = tf.Variable(tf.random_uniform([3]), name="input2")
output = tf.add_n([input1, input2], name="add")

# 生成一个写日志的 writer，并将当前的 TensorFlow 计算图写入日志。TensorFlow 提供了多
# 种写日志文件的 API，在 9.3 节中将详细介绍。
writer = tf.train.SummaryWriter("/path/to/log", tf.get_default_graph())
writer.close()
```

以上程序输出了 TensorFlow 计算图的信息，所以运行 TensorBoard 时，可以看到这个向量相加程序计算图可视化之后的结果。TensorBoard 不需要额外的安装过程，在 TensorFlow 安装完成时，TensorBoard 会被自动安装。运行下面的命令可以启动 TensorBoard。

```
# 运行 TensorBoard，并将日志的地址指向上面程序日志输出的地址。
tensorboard --logdir=/path/to/log
```

运行上面的命令会启动一个服务，这个服务的端口默认为 6006^①。通过浏览器打开 localhost:6006，可以看到图 9-1 所示的界面。在界面的上方，可以看到有五栏，分别是 EVENTS、IMAGES、AUDIO、GRAPHS 和 HISTOGRAMS。TensorBoard 中每一栏都对应了一类信息的可视化结果，在下面的章节中将具体介绍每一栏的功能。如图 9-1 所示，打开 TensorBoard 界面会默认进入 EVENTS 栏。因为上面的程序没有输出任何由 EVENTS 栏可视化的信息，所以这个界面显示的是 “No scalar data was found.”（没有发现标量数据）。点击进入 GRAPHS 栏，可以看到上面程序 TensorFlow 计算图的可视化结果。图 9-2 展示了这个 TensorFlow 计算图的可视化结果。9.2 节将详细介绍如何理解 TensorFlow 计算图的可视化结果中提供的信息。

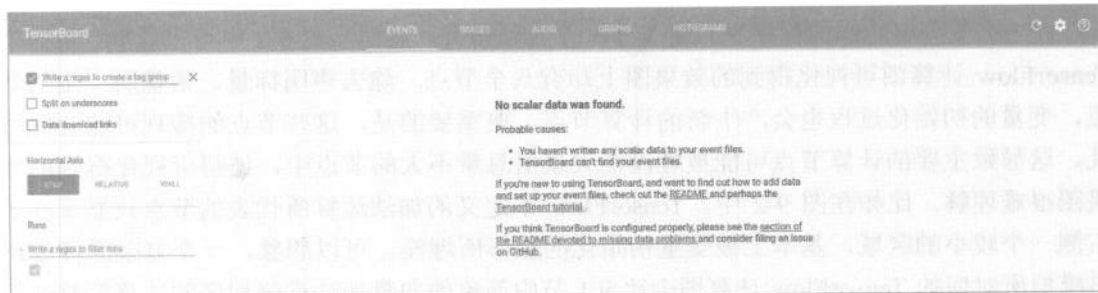


图 9-1 TensorBoard 默认栏界面

① 使用 --port 参数可以改变启动服务的端口。

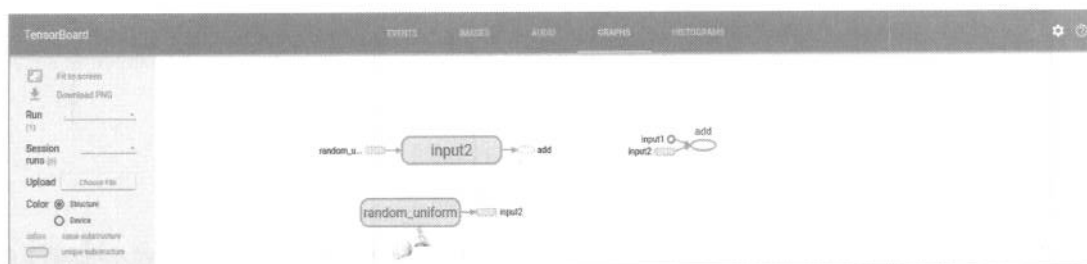


图 9-2 使用 TensorBoard 可视化向量相加程序 TensorFlow 计算图的结果

9.2 TensorFlow 计算图可视化

在图 9-2 中给出了一个 TensorFlow 计算图的可视化效果图。然而，从 TensorBoard 可视化结果中可以获取的信息远不止图 9-2 中所示的这些。这一节将详细介绍如何更好地利用 TensorFlow 计算图的可视化结果。首先，9.2.1 小节将介绍通过 TensorFlow 节点的命名空间整理 TensorBoard 可视化得到的 TensorFlow 计算图。在第 3 章中介绍过，TensorFlow 会将所有的计算以图的形式组织起来。TensorBoard 可视化得到的图并不仅是将 TensorFlow 计算图中的节点和边直接可视化，它会根据每个 TensorFlow 计算节点的命名空间来整理可视化得到的效果图，使得神经网络的整体结构不会被过多的细节所淹没。除了显示 TensorFlow 计算图的结构，TensorBoard 还可以展示 TensorFlow 计算节点上的其他信息。然后，9.2.2 小节将详细介绍如何从可视化结果中获取 TensorFlow 计算图中的这些信息。

9.2.1 命名空间与 TensorBoard 图上节点

在 9.1 节给出的样例程序中只定义了一个加法操作，然而从图 9-2 中可以看到，将这个 TensorFlow 计算图可视化得到的效果图上却有八个节点。除去声明标量、常量所产生的节点，变量的初始化过程也会产生新的计算节点。更重要的是，这些节点的排列可能会比较乱，这导致主要的计算节点可能被埋没在大量信息量不大的节点中，使得可视化得到的效果图很难理解。比如在图 9-2 中，TensorFlow 中定义的加法运算所代表的节点只显示在了右侧一个较小的区域，基本上被变量初始化的操作所埋没。可以想象，一个复杂的神经网络模型所对应的 TensorFlow 计算图会比 9.1 节中简单的向量加法样例程序的计算图复杂很多，那么没有经过整理得到的可视化效果图并不能帮助很好地理解神经网络模型的结构。

为了更好地组织可视化效果图中的计算节点，TensorBoard 支持通过 TensorFlow 命名空间来整理可视化效果图上的节点。在 TensorBoard 的默认视图中，TensorFlow 计算图中

同一个命名空间下的所有节点会被缩略成一个节点，只有顶层命名空间中的节点才会被显示在 TensorBoard 可视化效果图上。在 5.3 节中已经介绍过变量的命名空间，以及如何通过 `tf.variable_scope` 函数管理变量的命名空间。除了 `tf.variable_scope` 函数，`tf.name_scope` 函数也提供了命名空间管理的功能。这两个函数在大部分情况下是等价的，唯一的区别是在使用 `tf.get_variable` 函数时。以下代码简单地说明了这两个函数的区别。

```
import tensorflow as tf

with tf.variable_scope("foo"):
    # 在命名空间 foo 下获取变量 "bar"，于是得到的变量名称为 "foo/bar"。
    a = tf.get_variable("bar", [1])
    print a.name                    # 输出: foo/bar:0

with tf.variable_scope("bar"):
    # 在命名空间 bar 下获取变量 "bar"，于是得到的变量名称为 "bar/bar"。此时变量
    # "bar/bar" 和变量 "foo/bar" 并不冲突，于是可以正常运行。
    b = tf.get_variable("bar", [1])
    print b.name                    # 输出: bar/bar:0

with tf.name_scope("a"):
    # 使用 tf.Variable 函数生成变量会受 tf.name_scope 影响，于是这个变量的名称
    # 为 "a/Variable"。
    a = tf.Variable([1])
    print a.name                    # 输出: a/Variable:0

    # tf.get_variable 函数不受 tf.name_scope 函数的影响，
    # 于是变量并不在 a 这个命名空间中。
    a = tf.get_variable("b", [1])
    print a.name                    # 输出: b:0

with tf.name_scope("b"):
    # 因为 tf.get_variable 不受 tf.name_scope 影响，所以这里将试图获取名称
    # 为 "a" 的变量。然而这个变量已经被声明了，于是这里会报重复声明的错误：
    # ValueError: Variable bar already exists, disallowed. Did you mean
    # to set reuse=True in VarScope? Originally defined at: ...
    tf.get_variable("b", [1])
```

通过对命名空间管理，可以改进 9.1 节中向量相加的样例代码，使得可视化得到的效果图更加清晰。以下代码展示了改进的方法。

```
import tensorflow as tf

# 将输入定义放入各自的命名空间中，从而使得 TensorBoard 可以根据命名空间来整理可视化效
# 果图上的节点。
with tf.name_scope("input1"):
    input1 = tf.constant([1.0, 2.0, 3.0], name="input1")
```



```
with ctf.name_scope("input2"):  
    input2 = tf.Variable(tf.random_uniform([3]), name="input2")  
    output = tf.add_n([input1, input2], name="add")  
  
writer = tf.train.SummaryWriter("/path/to/log", tf.get_default_graph())  
writer.close()
```

图 9-3 中显示了改进后的可视化效果图。从图中可以看到，图 9-2 中很多的节点都被缩略到了图 9-3 中的 input2 节点。这样 TensorFlow 程序中定义的加法运算被清晰地展示了出来。需要查看 input2 节点中具体包含了哪些运算时，可以将鼠标移动到 input2 节点，并点开右上角的加号“+”^①。图 9-4 显示了展开 input2 节点之后的视图。




图 9-3 改进后向量加法程序 TensorFlow 计算图的可视化效果图

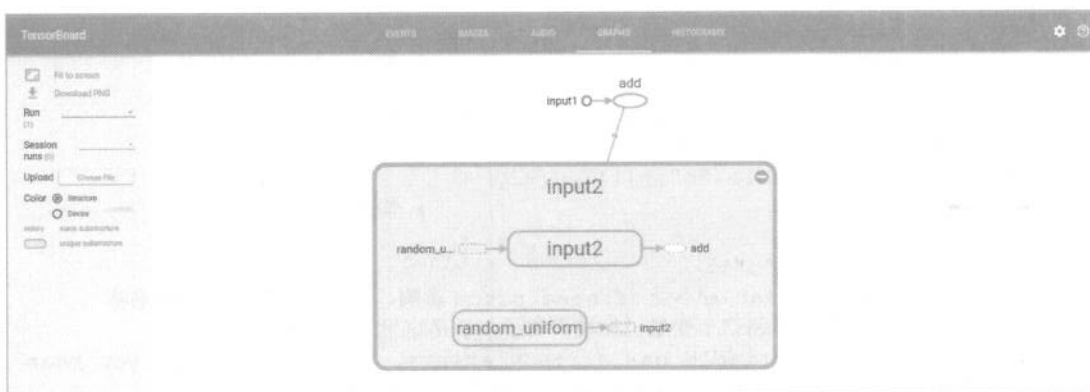


图 9-4 展开 input2 节点的可视化效果图

在 input2 的展开图中可以看到图 9-2 中数据初始化相关的操作都被整理到了一起。下面将给出一个样例程序来展示如何很好地可视化一个真实的神经网络结构图。本节将继续采用 5.5 节中给出的架构，以下代码给出了改造后的 mnist_train.py 程序。

^① “+”号会在鼠标移动到这个节点时显示在节点的右上角。

```

import tensorflow as tf
from tensorflow.examples.tutorials.mnist import input_data
# mnist_inference 中定义的常量和前向传播的函数不需要改变，因为前向传播已经通过
# tf.variable_scope 实现了计算节点按照网络结构的划分。
import mnist_inference

INPUT_NODE = 784
OUTPUT_NODE = 10
LAYER1_NODE = 500

def train(mnist):
    # 将处理输入数据的计算都放在名字为“input”的命名空间下。
    with tf.name_scope('input'):
        x = tf.placeholder(
            tf.float32, [None, mnist_inference.INPUT_NODE], name='x-input')
        y_ = tf.placeholder(
            tf.float32, [None, mnist_inference.OUTPUT_NODE],
            name='y-input')

        regularizer = tf.contrib.layers.l2_regularizer(REGULARAZTION_RATE)
        y = mnist_inference.inference(x, regularizer)
        global_step = tf.Variable(0, trainable=False)

    # 将处理滑动平均相关的计算都放在名为 moving_average 的命名空间下。
    with tf.name_scope("moving_average"):
        variable_averages = tf.train.ExponentialMovingAverage(
            MOVING_AVERAGE_DECAY, global_step)
        variables_averages_op = variable_averages.apply(
            tf.trainable_variables())

    # 将计算损失函数相关的计算都放在名为 loss_function 的命名空间下。
    with tf.name_scope("loss_function"):
        cross_entropy = tf.nn.sparse_softmax_cross_entropy_with_logits(
            y, tf.argmax(y, 1))
        cross_entropy_mean = tf.reduce_mean(cross_entropy)
        loss = cross_entropy_mean + tf.add_n(tf.get_collection('losses'))

    # 将定义学习率、优化方法以及每一轮训练需要执行的操作都放在名字为“train_step”
    # 的命名空间下。
    with tf.name_scope("train_step"):
        learning_rate = tf.train.exponential_decay(
            LEARNING_RATE_BASE,
            global_step,
            mnist.train.num_examples / BATCH_SIZE,
            LEARNING_RATE_DECAY,
            staircase=True)
        train_step = tf.train.GradientDescentOptimizer(learning_rate)\
            .minimize(loss, global_step=global_step)

```

```

with tf.control_dependencies([train_step, variables_averages_op]):
    train_op = tf.no_op(name='train')

# 使用和 5.5 节中一样的方式训练神经网络。
...

# 将当前的计算图输出到 TensorBoard 日志文件。
writer = tf.train.SummaryWriter("/path/to/log", tf.get_default_graph())
writer.close()

def main(argv=None):
    mnist = input_data.read_data_sets("/tmp/data", one_hot=True)
    train(mnist)

if __name__ == '__main__':
    tf.app.run()

```

相比 5.5 节中给出的 `mnist_train.py` 程序，上面程序最大的改变就是将完成类似功能的计算放到了由 `tf.name_scope` 函数生成的上下文管理器中。这样 TensorBoard 可以将这些节点有效地合并，从而突出神经网络的整体结构。因为在 `mnist_inference.py` 程序中已经使用了 `tf.variable_scope` 来管理变量的命名空间，所以这里不需要再做调整。图 9-5 展示了新的 MNIST 程序的 TensorFlow 计算图可视化得到的效果图。

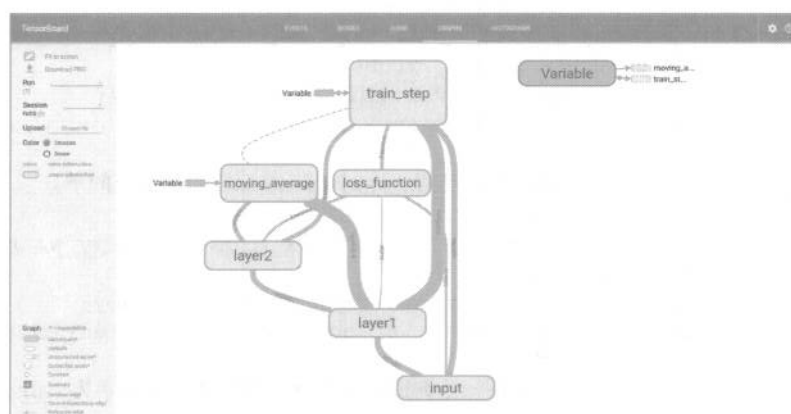


图 9-5 改进后的 MNIST 样例程序 TensorFlow 计算图可视化效果图

从图 9-5 中可以看到，TensorBoard 可视化效果图很好的展示了整个神经网络的结构。在图 9-5 中，`input` 节点代表了训练神经网络需要的输入数据，这些输入数据会提供给神经网络的第一层 `layer1`。然后神经网络第一层 `layer1` 的结果会被传到第二层 `layer2`，经过 `layer2` 的计算得到前向传播的结果。`loss_function` 节点表示计算损失函数的过程，这个过程既依赖于前向传播的结果来计算交叉熵（`layer2` 到 `loss_function` 的边），又依赖于每一层中所定义

的变量来计算 L2 正则化损失 (layer1 和 layer2 到 loss_function 的边)。loss_function 的计算结果会提供给神经网络的优化过程,也就是图中 train_step 所代表的节点。综上所述,通过 TensorBoard 可视化得到的效果图可以对整个神经网络的网络结构有一个大致了解。

在图 9-5 中可以发现节点之间有两种不同的边。一种边是通过实线表示的,这种边刻画了数据传输,边上箭头方向表达了数据传输的方向。比如 layer1 和 layer2 之间的边表示了 layer1 的输出将会作为 layer2 的输入。有些边上的箭头是双向的,比如节点 Variable 和 train_step 之间的边。这表明 train_step 会修改 Variable 的状态,在这里也就是表明训练过程会修改记录训练迭代轮数的变量^①。

TensorBoard 可视化效果图的边上还标注了张量的维度信息。图 9-6 放大了可视化得到的效果图,从图中可以看出,节点 input 和 layer1 之间传输的张量的维度为 100×784 。这说明了训练时提供的 batch 大小为 100,输入层节点的个数为 784。当两个节点之间传输的张量多于 1 个时,可视化效果图上将只显示张量的个数。效果图上边的粗细表示的是两个节点之间传输的标量维度的总大小,而不是传输的标量个数。比如 layer2 和 loss_function 之间虽然传输了两个张量,但其维度都比较小,所以这条边比 layer1 和 layer2 之间的边还要细。




图 9-6 TensorBoard 可视化效果图中边上信息

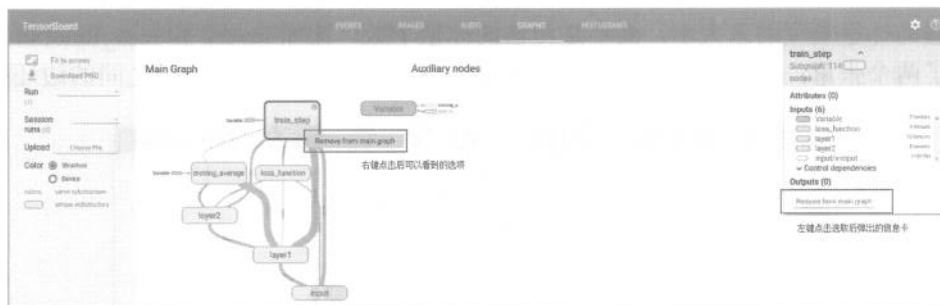
TensorBoard 可视化效果图上另外一种边是通过虚线表示的,比如图 9-5 中所示的 moving_average 和 train_step 之间的边。虚边表达了计算之间的依赖关系,比如在程序中,通过 tf.control_dependencies 函数指定了更新参数滑动平均值的操作和通过反向传播更新变量的操作需要同时进行,于是 moving_average 与 train_step 之间存在一条虚边。

除了手动的通过 TensorFlow 中的命名空间来调整 TensorBoard 的可视化效果图,TensorBoard 也会智能地调整可视化效果图上的节点。TensorFlow 中部分计算节点会有比较


^① 注意这里“Variable”表示名称为 Variable 的变量,而不是所有神经网络中的参数。在样例程序中,名称为 Variable 的变量是存储训练迭代轮数的变量。

多的依赖关系，如果全部画在一张图上会使可视化得到的效果图非常拥挤。于是 TensorBoard 将 TensorFlow 计算图分成了主图（Main Graph）和辅助图（Auxiliary nodes）两个部分来呈现。在图 9-5 中，左侧展示的是计算图的主要部分，也就是主图；右侧展示的是一些单独列出来的节点，也就是辅助图。TensorBoard 会自动将连接比较多的节点放在辅助图中，使得主图的结构更加清晰。

除了自动的方式，TensorBoard 也支持手工的方式来调整可视化结果。如图 9-7 所示，右键单击可视化效果图上的节点会弹出一个选项，这个选项可以将节点加入主图或者从主图中删除。左键选择一个节点并点击信息框下部的选项也可以完成类似的功能。图 9-8 展示了将 `train_step` 节点从主图中移出后的效果，图 9-9 展示了将 `Variable` 节点移入主图后的效果。注意 TensorBoard 不会保存用户对计算图可视化结果的手工修改，页面刷新之后计算图可视化结果又会回到最初的样子。



(a) 手工将 TensorFlow 计算图可视化效果图中节点移出主图



(b) 手工将 TensorFlow 计算图可视化效果图中节点加入主图

图 9-7 手工将 TensorFlow 计算图可视化效果图中节点加入/移出主图

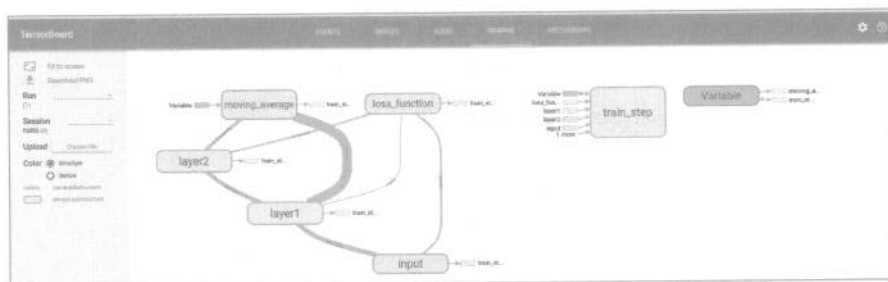


图 9-8 将 train_step 节点从主图中移出后的效果图

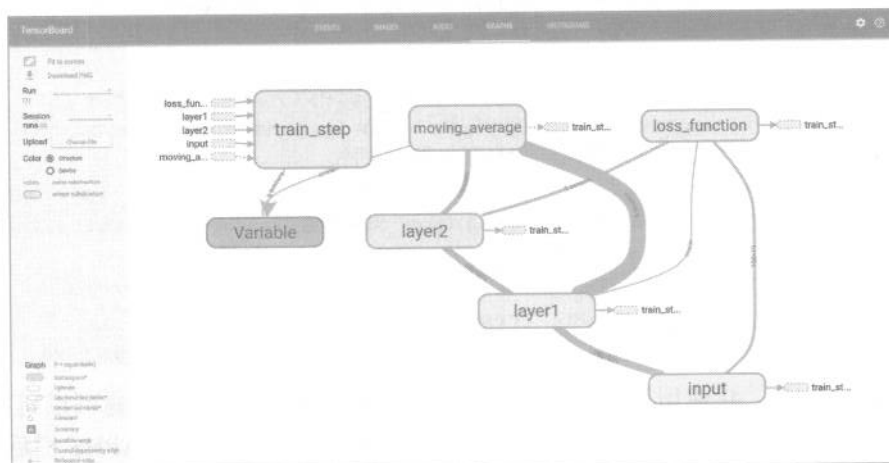


图 9-9 将 Variable 节点移入主图后的效果图

9.2.2 节点信息

除了展示 TensorFlow 计算图的结构，TensorBoard 还可以展示 TensorFlow 计算图上每个节点的基本信息以及运行时消耗的时间和空间。本小节将进一步讲解如何通过 TensorBoard 展现 TensorFlow 计算图节点上的这些信息。TensorFlow 计算节点的运行时间都是非常有用的信息，它可以帮助更加有针对性地优化 TensorFlow 程序，使得整个程序的运行速度更快。使用 TensorBoard 可以非常直观地展现所有 TensorFlow 计算节点在某一次运行时所消耗的时间和内存。将以下代码加入 9.2.1 小节中修改后的 mnist_train.py 神经网络训练部分，就可以将不同迭代轮数时每一个 TensorFlow 计算节点的运行时间和消耗的内存写入 TensorBoard 的日志文件中。

```
with tf.Session() as sess:
    tf.initialize_all_variables().run()
```



```

for i in range(TRAINING_STEPS):
    xs, ys = mnist.train.next_batch(BATCH_SIZE)

    # 每 1000 轮记录一次运行状态。
    if i % 1000 == 0:
        # 配置运行时需要记录的信息。
        run_options = tf.RunOptions(
            trace_level=tf.RunOptions.FULL_TRACE)
        # 运行时记录运行信息的 proto。
        run_metadata = tf.RunMetadata()
        # 将配置信息和记录运行信息的 proto 传入运行的过程, 从而记录运行时每一个
        # 节点的时间、空间开销信息。
        _, loss_value, step = sess.run(
            [train_op, loss, global_step], feed_dict={x: xs, y_: ys},
            options=run_options, run_metadata=run_metadata)
        # 将节点在运行时的信息写入日志文件。
        train_writer.add_run_metadata(run_metadata, 'step%03d' % i)
        print("After %d training step(s), loss on training batch "
              "is %g." % (step, loss_value))
    else:
        _, loss_value, step = sess.run(
            [train_op, loss, global_step], feed_dict={x: xs, y_: ys})

```

运行以上程序, 并使用这个程序输出的日志启动 TensorBoard, 就可以可视化每个 TensorFlow 计算节点在某一次运行时所消耗的时间和空间了。进入 GRAPHS 栏后, 需要先选择一次运行来查看。如图 9-10 (a) 所示, 点击页面左侧的 Session runs 选项会出现一个下拉单, 在这个下拉单中会出现所有通过 `train_writer.add_run_metadata` 函数记录的运行数据。如图 9-10(b) 所示, 选择一次运行后, TensorBoard 左侧的 Color 栏中将会新出现 Compute time 和 Memory 这两个选项。



(a) 选择运行记录的页面

(b) 选择完运行记录后 Color 栏多出来的选项

图 9-10 TensorBoard 运行记录选择界面

在 Color 栏中选择 Compute time 可以看到在这次运行中每个 TensorFlow 计算节点的运行时间。类似的，选择 Memory 可以看到这次运行中每个 TensorFlow 计算节点所消耗的内存。图 9-11 展示了在第 10000 轮迭代时，不同 TensorFlow 计算节点时间消耗的可视化效果图。图中颜色越深的节点表示时间消耗越大。从图 9-11 中可以看出，代表训练神经网络的 `train_step` 节点消耗的时间是最多的。通过对每一个计算节点消耗时间的可视化，可以很容易地找到 TensorFlow 计算图上的性能瓶颈，这大大方便了算法优化的工作。在性能调优时，一般会选择迭代轮数较大时的数据（比如图 9-11 中第 10000 轮迭代时的数据）作为不同计算节点时间/空间消耗的标准，因为这样可以减少 TensorFlow 初始化对性能的影响。

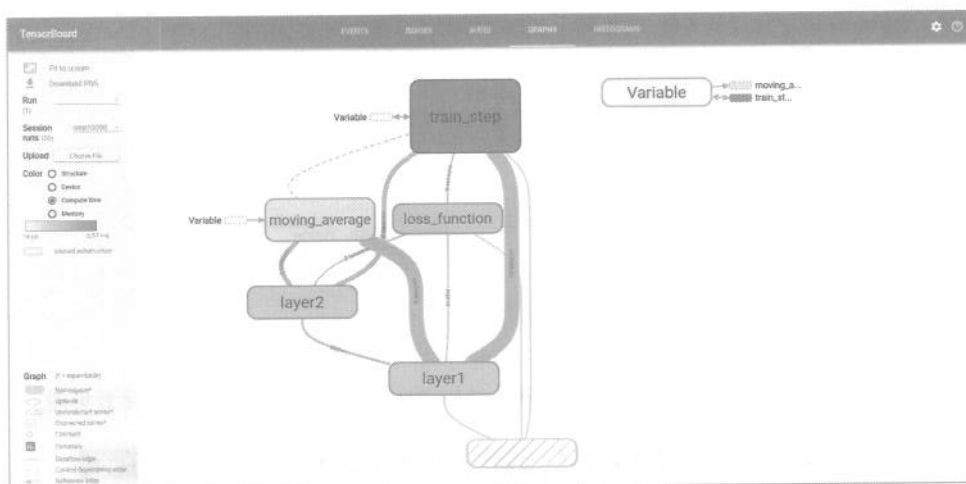


图 9-11 第 10000 轮迭代时不同 TensorFlow 计算节点时间消耗的可视化效果图

在 TensorBoard 界面左侧的 Color 栏中，除了 Compute time 和 Memory，还有 Structure 和 Device 两个选项。在图 9-3 到图 9-9 中，展示的可视化效果图都是使用默认的 Structure 选项。在这个视图中，灰色的节点表示没有其他节点和它拥有相同结构。如果有两个节点的结构相同，那么它们会被涂上相同的颜色。图 9-12 展示了一个拥有相同结构节点的卷积神经网络可视化得到的效果图。在图 9-12 中，两个卷积层的结构是一样的，所以他们都被涂上了相同的颜色。最后，Color 栏还可以选择 Device 选项，这个选项可以根据 TensorFlow 计算节点运行的机器给可视化效果图上的节点染色。在使用 GPU 时，可以通过这种方式直观地看到哪些计算节点被放到了 GPU 上。图 9-13 给出了一个使用了 GPU 的 TensorFlow 计算图的可视化结果。图 9-13 中深灰色的节点表示对应的计算放在了 GPU 上，浅灰色的节点表示对应的计算放在了 CPU 上。具体如何使用 GPU 将在第 10 章介绍。

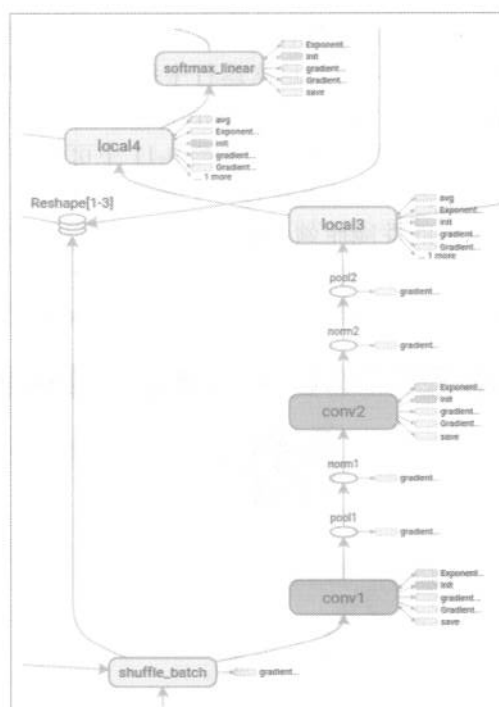


图 9-12 有相同结构节点的卷积神经网络计算图在 Structure 选项下的可视化效果图

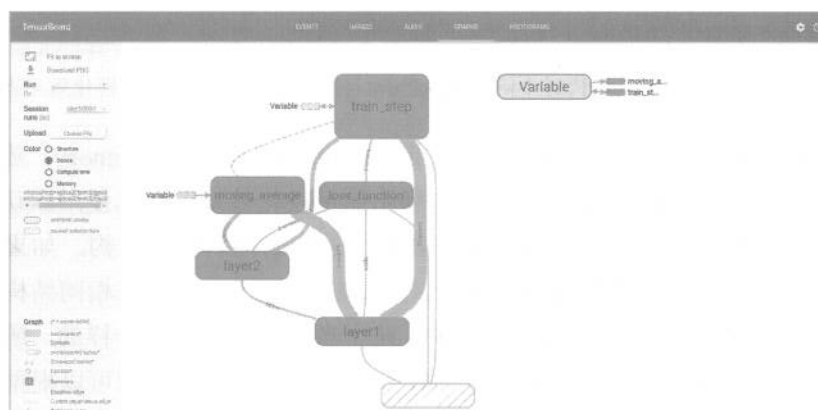


图 9-13 使用了 GPU 的 TensorFlow 计算图的可视化结果

当点击 TensorBoard 可视化效果图中的节点时,界面的右上角会弹出一个信息卡片显示这个节点的基本信息。如图 9-14 所示,当点击的节点为一个命名空间时, TensorBoard 展示的信息有这个命名空间内所有计算节点的输入、输出以及依赖关系。虽然属性 (Attributes) 也会展示在卡片中,但是在代表命名空间的属性下不会有任何内容。当 Session

runs 选择了某一次运行时，节点的信息卡片上也会出现这个节点运行时所消耗的时间和内存等信息。

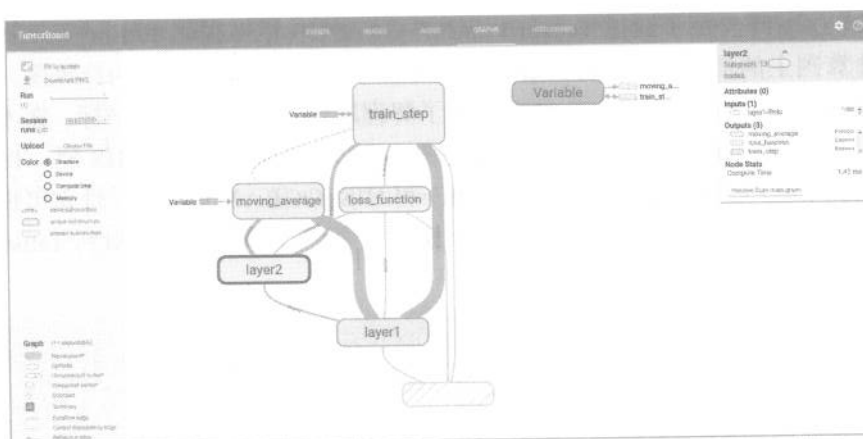


图 9-14 TensorFlow 命名空间在 TensorBoard 可视化效果图上的信息卡片

当点击的 TensorBoard 可视化效果图上的节点对应一个 TensorFlow 计算节点时，TensorBoard 也会展示类似的信息。图 9-15 展示了一个 TensorFlow 计算节点所对应的信息卡片。在 TensorBoard 页面中，空心的小椭圆对应了 TensorFlow 计算图上的一个计算节点，而一个矩形对应了计算图上的一个命名空间。TensorFlow 计算节点所对应的信息卡片中的内容和命名空间信息卡片相似，只是 TensorBoard 可以将 TensorFlow 计算节点的属性也展示出来。例如在图 9-15 中，属性栏下显示了选中的计算节点是在什么设备上运行的，以及运行这个计算时的两个参数。




图 9-15 TensorFlow 计算节点在 TensorBoard 可视化效果图上的信息卡片

9.3 监控指标可视化

在 9.2 节中着重介绍了通过 TensorBoard 的 GRAPHS 栏可视化 TensorFlow 计算图的结构以及在计算图上的信息。TensorBoard 除了可以可视化 TensorFlow 的计算图，还可以可视化 TensorFlow 程序运行过程中各种有助于了解程序运行状态的监控指标。在本节中将介绍如何利用 TensorBoard 中其他栏目可视化这些监控指标。除了 GRAPHS 栏，TensorBoard 界面中还提供了 EVENTS、IMAGES、AUDIO 和 HISTOGRAMS 四个栏目来可视化其他的监控指标。下面的程序展示了如何将 TensorFlow 程序运行时的信息输出到 TensorBoard 日志文件中。

```
import tensorflow as tf
from tensorflow.examples.tutorials.mnist import input_data

SUMMARY_DIR = "/path/to/log"
BATCH_SIZE = 100
TRAIN_STEPS = 30000

# 生成变量监控信息并定义生成监控信息日志的操作。其中 var 给出了需要记录的张量，name 给
# 出了在可视化结果中显示的图表名称，这个名称一般与变量名一致。
def variable_summaries(var, name):
    # 将生成监控信息的操作放到同一个命名空间下。
    with tf.name_scope('summaries'):
        # 通过 tf.histogram_summary 函数记录张量中元素的取值分布。对于给出的图表名称
        # 和张量，tf.histogram_summary 函数会生成一个 Summary protocol buffer。
        # 将 Summary 写入 TensorBoard 日志文件后，可以在 HISTOGRAMS 栏下看到对应名
        # 称的图表。图 9-20 给出了一个可视化结果效果图。和 TensorFlow 中其他操作类似，
        # tf.histogram_summary 函数不会立刻被执行，只有当 sess.run 函数明确调用这
        # 个操作时，TensorFlow 才会真正生成并输出 Summary protocol buffer。
        tf.histogram_summary(name, var)

    # 计算变量的平均值，并定义生成平均值信息日志的操作。记录变量平均值信息的日志标签名
    # 为 'mean/' + name，其中 mean 为命名空间，/ 是命名空间的分隔符。从图 9-17
    # 中可以看到，在相同命名空间中的监控指标会被整合到同一栏中。name 则给出了当前监
    # 控指标属于哪一个变量。
    mean = tf.reduce_mean(var)
    tf.scalar_summary('mean/' + name, mean)
    # 计算变量的标准差，并定义生成其日志的操作。
    stddev = tf.sqrt(tf.reduce_mean(tf.square(var - mean)))
    tf.scalar_summary('stddev/' + name, stddev)

# 生成一层全链接神经网络。
def nn_layer(input_tensor, input_dim, output_dim,
             layer_name, act=tf.nn.relu):
```

```

# 将同一层神经网络放在一个统一的命名空间下。
with tf.name_scope(layer_name):
    # 声明神经网络边上的权重，并调用生成权重监控信息日志的函数。
    with tf.name_scope('weights'):
        weights = tf.Variable(tf.truncated_normal(
            [input_dim, output_dim], stddev=0.1))
        variable_summaries(weights, layer_name + '/weights')

    # 声明神经网络的偏置项，并调用生成偏置项监控信息日志的函数。
    with tf.name_scope('biases'):
        biases = tf.Variable(tf.constant(0.0, shape=[output_dim]))
        variable_summaries(biases, layer_name + '/biases')

    with tf.name_scope('Wx_plus_b'):
        preactivate = tf.matmul(input_tensor, weights) + biases
        # 记录神经网络输出节点在经过激活函数之前的分布。
        tf.histogram_summary(layer_name + '/pre_activations',
            preactivate)
        activations = act(preactivate, name='activation')

    # 记录神经网络输出节点在经过激活函数之后的分布。在图 9-20 中，对于 layer1，因
    # 为使用了 ReLU 函数作为激活函数，所以所有小于 0 的值都被设为了 0。于是在激活后
    # 的 layer1/activations 图上所有的值都是大于 0 的。而对于 layer2，因为没有使
    # 用激活函数，所以 layer2/activations 和 layer2/pre_activations 一样。
    tf.histogram_summary(layer_name + '/activations', activations)
    return activations

def main(_):
    mnist = input_data.read_data_sets("/tmp/data", one_hot=True)
    # 定义输入。
    with tf.name_scope('input'):
        x = tf.placeholder(tf.float32, [None, 784], name='x-input')
        y_ = tf.placeholder(tf.float32, [None, 10], name='y-input')

    # 将输入向量还原成图片的像素矩阵，并通过 tf.image_summary 函数定义将当前的图片信
    # 息写入日志的操作。
    with tf.name_scope('input_reshape'):
        image_shaped_input = tf.reshape(x, [-1, 28, 28, 1])
        tf.image_summary('input', image_shaped_input, 10)

    hidden1 = nn_layer(x, 784, 500, 'layer1')
    y = nn_layer(hidden1, 500, 10, 'layer2', act=tf.identity)

    # 计算交叉熵并定义生成交叉熵监控日志的操作。
    with tf.name_scope('cross_entropy'):
        cross_entropy = tf.reduce_mean(

```



```

        tf.nn.softmax_cross_entropy_with_logits(y, y_)
        tf.scalar_summary('cross entropy', cross_entropy)

with tf.name_scope('train'):
    train_step = tf.train.AdamOptimizer(0.001).minimize(cross_entropy)

# 计算模型在当前给定数据上的正确率, 并定义生成正确率监控日志的操作。如果在 sess.run
# 时给定的数据是训练 batch, 那么得到的正确率就是在这个训练 batch 上的正确率; 如果
# 给定的数据为验证或者测试数据, 那么得到的正确率就是在当前模型在验证或者测试数据上
# 的正确率。
with tf.name_scope('accuracy'):
    with tf.name_scope('correct_prediction'):
        correct_prediction = tf.equal(tf.argmax(y, 1), tf.argmax(y_, 1))
    with tf.name_scope('accuracy'):
        accuracy = tf.reduce_mean(
            tf.cast(correct_prediction, tf.float32))
        tf.scalar_summary('accuracy', accuracy)

# 和 TensorFlow 中其他操作类似, tf.scalar_summary、tf.histogram_summary
# 和 tf.image_summary 函数都不会立即执行, 需要通过 sess.run 来明确调用这些函数。
# 因为程序中定义的写日志操作比较多, 一一调用非常麻烦, 所以 TensorFlow 提供了
# tf.merge_all_summaries 函数来整理所有的日志生成操作。在 TensorFlow 程序执行
# 的过程中只需要运行这个操作就可以将代码中定义的所有日志生成操作执行一次, 从而将所
# 有日志写入文件。
merged = tf.merge_all_summaries()

with tf.Session() as sess:
    # 初始化写日志的 writer, 并将当前 TensorFlow 计算图写入日志。
    summary_writer = tf.train.SummaryWriter(SUMMARY_DIR, sess.graph)
    tf.initialize_all_variables().run()

    for i in range(TRAIN_STEPS):
        xs, ys = mnist.train.next_batch(BATCH_SIZE)
        # 运行训练步骤以及所有的日志生成操作, 得到这次运行的日志。
        summary, _ = sess.run([merged, train_step],
                               feed_dict={x: xs, y_: ys})
        # 将所有日志写入文件, TensorBoard 程序就可以拿到这次运行所对应的运行信息。
        summary_writer.add_summary(summary, i)

    summary_writer.close()

if __name__ == '__main__':
    tf.app.run()

```

从上面的程序可以看出, 除了 GRAPHS 之外, Tensorboard 中的每一栏对应了 TensorFlow 中一种日志生成函数, 表 9-1 总结了这个对应关系。

表 9-1 TensorFlow 日志生成函数与 TensorBoard 界面栏对应关系。

TensorFlow 日志生成函数	TensorBoard 界面栏	展示内容
tf.scalar_summary	EVENTS	TensorFlow 中标量 (scalar) 监控数据随着迭代进行的变化趋势。图 9-18 中展示了当前模型在训练 batch 上的正确率随着迭代进行的变化趋势。
tf.image_summary	IMAGES	TensorFlow 中使用的图片数据。这一栏一般用于可视化当前使用的训练/测试图片。图 9-19 中展示了例程序在最后一轮训练时使用的图片。
tf.audio_summary	AUDIO	TensorFlow 中使用的音频数据。
tf.histogram_summary	HISTOGRAMS	TensorFlow 中张量分布监控数据随着迭代轮数的变化趋势。图 9-20 中展示了神经网络参数取值分布随着迭代进行的变化趋势。

运行上面的样例程序并使用 9.1 节中介绍的方式启动 TensorBoard，可以看到如图 9-16 所示的界面。在这个页面上有 4 组不同的监控指标，这些指标都是样例程序中通过 `tf.scalar_summary` 函数生成的。和变量的命名空间类似，TensorBoard 也会根据监控指标的名称进行分组。从图 9-17 中可以看到，名称为 `mean` 的栏目下有 4 组不同的监控指标。这 4 个不同的指标都以 `mean` 开头，并通过斜线“/”划分不同的命名空间。不过和 TensorFlow 计算图可视化结果不同的是，EVENTS 栏只会对最高层的命名空间进行整合，单击展开后将看到该命名空间下的所有监控指标。




图 9-16 使用 TensorBoard 展示标量监控信息的默认页面

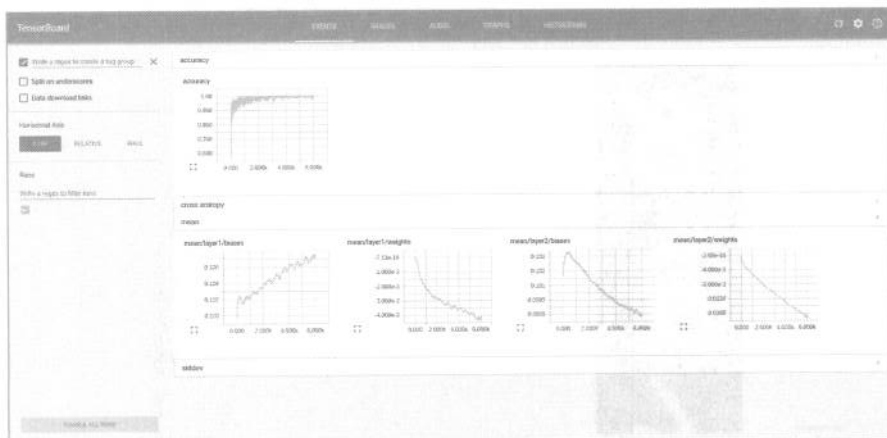


图 9-17 展开标量监控页面中的监控内容后得到的页面

在每一个监控指标的左下角有一个小方框“🔍”，单击这个方框可以得到放大后的图片。放大后的效果如图 9-18 所示。再单击一次这个小方框可以将放大后的图表缩小。在训练神经网络时，通过 TensorBoard 监控神经网络中变量取值的变化、模型在训练 batch 上的损失函数大小以及学习率的变化等信息可以更加方便地掌握模型的训练情况。




图 9-18 展开某一项监控标量时的放大图

图 9-19 展示了通过 TensorBoard 可视化当前轮训练使用的图像信息。通过这个界面可以大致看出数据随机打乱的效果。因为 TensorFlow 程序和 TensorBoard 可视化界面可以同时运行，所以从 TensorBoard 上可以实时看到 TensorFlow 程序中最新使用的训练或者测试图像。




图 9-19 通过 TensorBoard 可视化训练图像

TensorBoard 最后一栏提供了对张量取值分布的可视化界面。通过这个界面，可以直观地观察到不同层神经网络中参数的取值变化。



图 9-20 通过 TensorBoard 可视化张量取值分布效果图

小结

在本章中介绍了 TensorFlow 的可视化工具 TensorBoard。TensorBoard 是 TensorFlow 自带的工具，不需要额外的安装过程。虽然 TensorBoard 和 TensorFlow 运行在不同的进程中，但是 TensorBoard 会实时读取 TensorFlow 程序输出的日志文件从而获取最新的 TensorFlow 程序运行状态。通过 TensorBoard，一方面可以更好地了解 TensorFlow 计算图的结构以及每个 TensorFlow 计算节点在运行时的时间、内存消耗。另一方面也可以通过 TensorBoard 可视化神经网络模型训练过程中各种指标的变化趋势，直观地了解神经网络的训练情况。

第 10 章 TensorFlow 计算加速

在前面的章节中介绍了使用 TensorFlow 实现各种深度学习的算法。然而要将深度学习应用到实际问题中，一个非常大的问题在于训练深度学习模型需要的计算量太大。比如要将第 6 章中介绍的 Inception-v3 模型在单机上训练到 78% 的正确率需要将近半年的时间^①，这样的训练速度是完全无法应用到实际生产中的。为了加速训练过程，本章将介绍如何通过 TensorFlow 利用 GPU 或/和分布式计算进行模型训练。

首先，在 10.1 节中将介绍如何在 TensorFlow 中使用单个 GPU 进行计算加速，也将介绍生成 TensorFlow 会话（tf.Session）时的一些常用参数。通过这些参数可以使调试更加方便而且程序的可扩展性更好。然而，在很多情况下，单个 GPU 的加速效率无法满足训练大型深度学习模型的计算量需求，这时将需要利用更多的计算资源。为了同时利用多个 GPU 或者多台机器，10.2 节中将介绍训练深度学习模型的并行方式。然后，10.3 节将介绍如何在一台机器的多个 GPU 上并行化地训练深度学习模型。在这一节中也将给出具体的 TensorFlow 样例程序来使用多 GPU 训练模型，并比较并行化效率提升的比率。最后在 10.4 节中将介绍分布式 TensorFlow，以及如何通过分布式 TensorFlow 训练深度学习模型。在这一节中将给出具体的 TensorFlow 样例程序来实现不同的分布式深度学习训练模式。虽然 TensorFlow 可以支持分布式深度学习模型训练，但是它并不提供集群创建、管理等功能。为了方便地使用分布式 TensorFlow，10.4 节中将介绍才云科技基于 Kubernetes 容器云平台搭建的分布式 TensorFlow 系统。

10.1 TensorFlow 使用 GPU

TensorFlow 程序可以通过 tf.device 函数来指定运行每一个操作的设备，这个设备可以

^① 数字出自谷歌官方技术博客 <https://research.googleblog.com/2016/04/announcing-tensorflow-08-now-with.html>。

是本地的 CPU 或者 GPU，也可以是某一台远程的服务器。但在本节中只关心本地的设备。TensorFlow 会给每一个可用的设备一个名称，`tf.device` 函数可以通过设备的名称来指定执行运算的设备。比如 CPU 在 TensorFlow 中的名称为 `/cpu:0`。在默认情况下，即使机器有多个 CPU，TensorFlow 也不会区分它们，所有的 CPU 都使用 `/cpu:0` 作为名称。而一台机器上不同 GPU 的名称是不同的，第 n 个 GPU 在 TensorFlow 中的名称为 `/gpu:n`。比如第一个 GPU 的名称为 `/gpu:0`，第二个 GPU 名称为 `/gpu:1`，以此类推。

TensorFlow 提供了一个快捷的方式来查看运行每一个运算的设备。在生成会话时，可以通过设置 `log_device_placement` 参数来打印运行每一个运算的设备。下面的程序展示了如何使用 `log_device_placement` 这个参数。

```
import tensorflow as tf

a = tf.constant([1.0, 2.0, 3.0], shape=[3], name='a')
b = tf.constant([1.0, 2.0, 3.0], shape=[3], name='b')
c = a + b
# 通过 log_device_placement 参数来输出运行每一个运算的设备。
sess = tf.Session(config=tf.ConfigProto(log_device_placement=True))
print sess.run(c)

'''
在没有 GPU 的机器上运行以上代码可以得到以下输出：
Device mapping: no known devices.

add: /job:localhost/replica:0/task:0/cpu:0
b: /job:localhost/replica:0/task:0/cpu:0
a: /job:localhost/replica:0/task:0/cpu:0
[ 2.  4.  6.]
'''
```

在以上代码中，TensorFlow 程序生成会话时加入了参数 `log_device_placement=True`，所以程序会将运行每一个操作的设备输出到屏幕。于是除了可以看到最后的计算结果之外，还可以看到类似“`add: /job:localhost/replica:0/task:0/cpu:0`”这样的输出。这些输出显示了执行每一个运算的设备。比如加法操作 `add` 是通过 CPU 来运行的，因为它的设备名称中包含了 `/cpu:0`。

在配置好 GPU 环境的 TensorFlow 中^①，如果操作没有明确地指定运行设备，那么 TensorFlow 会优先选择 GPU。比如将以上代码在亚马逊（Amazon Web Services, AWS）的 `g2.8xlarge` 实例上运行时，会得到以下运行结果。

① 如何安装支持 GPU 的 TensorFlow 环境可以参考第 2 章。


```

Device mapping:
/job:localhost/replica:0/task:0/gpu:0 -> device: 0, name: GRID K520, pci bus
id: 0000:00:03.0
/job:localhost/replica:0/task:0/gpu:1 -> device: 1, name: GRID K520, pci bus
id: 0000:00:04.0
/job:localhost/replica:0/task:0/gpu:2 -> device: 2, name: GRID K520, pci bus
id: 0000:00:05.0
/job:localhost/replica:0/task:0/gpu:3 -> device: 3, name: GRID K520, pci bus
id: 0000:00:06.0

add: /job:localhost/replica:0/task:0/gpu:0
b: /job:localhost/replica:0/task:0/gpu:0
a: /job:localhost/replica:0/task:0/gpu:0
[ 2.  4.  6.]

```

从上面的输出可以看到在配置好 GPU 环境的 TensorFlow 中, TensorFlow 会自动优先将运算放置在 GPU 上。不过, 尽管 g2.8xlarge 实例有 4 个 GPU, 在默认情况下, TensorFlow 只会将运算优先放到 /gpu:0 上。于是可以看见在上面的程序中, 所有的运算都被放在了 /gpu:0 上。如果需要将某些运算放到不同的 GPU 或者 CPU 上, 就需要通过 tf.device 来手工指定。下面的程序给出了一个通过 tf.device 手工指定运行设备的样例。

```

import tensorflow as tf

# 通过 tf.device 将运算指定到特定的设备上。
with tf.device('/cpu:0'):
    a = tf.constant([1.0, 2.0, 3.0], shape=[3], name='a')
    b = tf.constant([1.0, 2.0, 3.0], shape=[3], name='b')
with tf.device('/gpu:1'):
    c = a + b

sess = tf.Session(config=tf.ConfigProto(log_device_placement=True))
print sess.run(c)

'''
在 AWS g2.8xlarge 实例上运行上述代码可以得到以下结果:
Device mapping:
/job:localhost/replica:0/task:0/gpu:0 -> device: 0, name: GRID K520, pci bus
id: 0000:00:03.0
/job:localhost/replica:0/task:0/gpu:1 -> device: 1, name: GRID K520, pci bus
id: 0000:00:04.0
/job:localhost/replica:0/task:0/gpu:2 -> device: 2, name: GRID K520, pci bus
id: 0000:00:05.0
'''

```

```

/job:localhost/replica:0/task:0/gpu:3 -> device: 3, name: GRID K520, pci bus
id: 0000:00:06.0

add: /job:localhost/replica:0/task:0/gpu:1
b: /job:localhost/replica:0/task:0/cpu:0
a: /job:localhost/replica:0/task:0/cpu:0
[ 2.  4.  6.]
'''

```

在以上代码中可以看到生成常量 `a` 和 `b` 的操作被加载到了 CPU 上，而加法操作被放到了第二个 GPU “/gpu:1” 上。在 TensorFlow 中，不是所有的操作都可以被放在 GPU 上，如果强行将无法放在 GPU 上的操作指定到 GPU 上，那么程序将会报错。以下代码给出了一个报错的样例。

```

import tensorflow as tf

# 在CPU上运行tf.Variable
a_cpu = tf.Variable(0, name="a_cpu")

with tf.device('/gpu:0'):
    # 将tf.Variable强制放在GPU上。
    a_gpu = tf.Variable(0, name="a_gpu")

sess = tf.Session(config=tf.ConfigProto(log_device_placement=True))
sess.run(tf.initialize_all_variables())

'''
运行上面的程序将会报出以下错误:
tensorflow.python.framework.errors.InvalidArgumentError: Cannot assign a
device to node 'a_gpu': Could not satisfy explicit device specification
'/device:GPU:0' because no supported kernel for GPU devices is available.
Colocation Debug Info:
Colocation group had the following types and devices:
Identity: CPU
Assign: CPU
Variable: CPU
[[Node: a_gpu = Variable[container="", dtype=DT_INT32, shape=[], shared_
name="", _device="/device:GPU:0"]()] ]
'''

```

不同版本的 TensorFlow 对 GPU 的支持不一样，如果程序中全部使用强制指定设备的

方式会降低程序的可移植性。在 TensorFlow 的 kernel^①中定义了哪些操作可以跑在 GPU 上。比如可以在 `variable_ops.cc` 程序中找到以下定义。

```
# define REGISTER_GPU_KERNELS(type)
REGISTER_KERNEL_BUILDER(
    Name("Variable").Device(DDEVICE_GPU).TypeConstraint<type>("dtype"), \
    VariableOp);
...
TF_CALL_GPU_NUMBER_TYPES(REGISTER_GPU_KERNELS);
```

在这段定义中可以看到 GPU 只在部分数据类型上支持 `tf.Variable` 操作。如果在 TensorFlow 代码库中搜索调用这段代码的宏 `TF_CALL_GPU_NUMBER_TYPES`，可以发现 GPU 上，`tf.Variable` 操作只支持实数型（`float16`、`float32` 和 `double`）的参数。而在报错的样例代码中给定的参数是整数型的，所以不支持在 GPU 上运行。为避免这个问题，TensorFlow 在生成会话时可以指定 `allow_soft_placement` 参数。当 `allow_soft_placement` 参数设置为 `True` 时，如果运算无法由 GPU 执行，那么 TensorFlow 会自动将它放到 CPU 上执行。以下代码给出了一个使用 `allow_soft_placement` 参数的样例。

```
import tensorflow as tf

a_cpu = tf.Variable(0, name="a_cpu")
with tf.device('/gpu:0'):
    a_gpu = tf.Variable(0, name="a_gpu")

# 通过 allow_soft_placement 参数自动将无法放在 GPU 上的操作放回 CPU 上。
sess = tf.Session(config=tf.ConfigProto(
    allow_soft_placement=True, log_device_placement=True))
sess.run(tf.initialize_all_variables())

...
运行上面这段程序可以得到下面的结果：
Device mapping:
/job:localhost/replica:0/task:0/gpu:0 -> device: 0, name: GRID K520, pci bus
id: 0000:00:03.0
/job:localhost/replica:0/task:0/gpu:1 -> device: 1, name: GRID K520, pci bus
id: 0000:00:04.0
/job:localhost/replica:0/task:0/gpu:2 -> device: 2, name: GRID K520, pci bus
id: 0000:00:05.0
/job:localhost/replica:0/task:0/gpu:3 -> device: 3, name: GRID K520, pci bus
```

① TensorFlow kernel 在 Github 的 <https://github.com/tensorflow/tensorflow/tree/master/tensorflow/core/kernels> 目录下。

```

id: 0000:00:06.0
a_gpu: /job:localhost/replica:0/task:0/cpu:0
a_gpu/read: /job:localhost/replica:0/task:0/cpu:0
a_gpu/Assign: /job:localhost/replica:0/task:0/cpu:0
init/NoOp_1: /job:localhost/replica:0/task:0/gpu:0
a_cpu: /job:localhost/replica:0/task:0/cpu:0
a_cpu/read: /job:localhost/replica:0/task:0/cpu:0
a_cpu/Assign: /job:localhost/replica:0/task:0/cpu:0
init/NoOp: /job:localhost/replica:0/task:0/gpu:0
init: /job:localhost/replica:0/task:0/gpu:0
a_gpu/initial_value: /job:localhost/replica:0/task:0/gpu:0
a_cpu/initial_value: /job:localhost/replica:0/task:0/cpu:0
从输出的日志中可以看到在生成变量 a_gpu 时,无法放到 GPU 上的运算被自动调整到了 CPU 上(比
如 a_gpu 和 a_gpu/read),而可以被 GPU 执行的命令(比如 a_gpu/initial_value)依旧由
GPU 执行。
'''

```

虽然 GPU 可以加速 TensorFlow 的计算,但一般来说不会把所有的操作全部放在 GPU 上。一个比较好的实践是将计算密集型的运算放在 GPU 上,而把其他操作放到 CPU 上。GPU 是机器中相对独立的资源,将计算放入或者转出 GPU 都需要额外的时间。而且 GPU 需要将计算时用到的数据从内存复制到 GPU 设备上,这也需要额外的时间。TensorFlow 可以自动完成这些操作而不需要用户特别处理,但为了提高程序运行的速度,用户也需要尽量将相关的运算放在同一个设备上。

10.2 深度学习训练并行模式

TensorFlow 可以很容易地利用单个 GPU 加速深度学习模型的训练过程,但要利用更多的 GPU 或者机器,需要了解如何并行化地训练深度学习模型。常用的并行化深度学习模型训练方式有两种,同步模式和异步模式。本节中将介绍这两种模式的工作方式及其优劣。

为帮助读者理解这两种训练模式,本节首先简单回顾一下如何训练深度学习模型。图 10-1 展示了深度学习模型的训练流程图。深度学习模型的训练是一个迭代的过程。在每一轮迭代中,前向传播算法会根据当前参数的取值计算出在一小部分训练数据上的预测值,然后反向传播算法再根据损失函数计算参数的梯度并更新参数。在并行化地训练深度学习模型时,不同设备(GPU 或 CPU)可以在不同训练数据上运行这个迭代的过程,而不同并行模式的区别在于不同的参数更新方式。

图 10-2 展示了异步模式的训练流程图。从图 10-2 中可以看到,在每一轮迭代时,不同设备会读取参数最新的取值,但因为不同设备读取参数取值的时间不一样,所以得到的

值也有可能不一样。根据当前参数的取值和随机获取的一小部分训练数据，不同设备各自运行反向传播的过程并独立地更新参数。可以简单地认为异步模式就是单机模式复制了多份，每一份使用不同的训练数据进行训练。在异步模式下，不同设备之间是完全独立的。




图 10-1 深度学习模型训练流程图

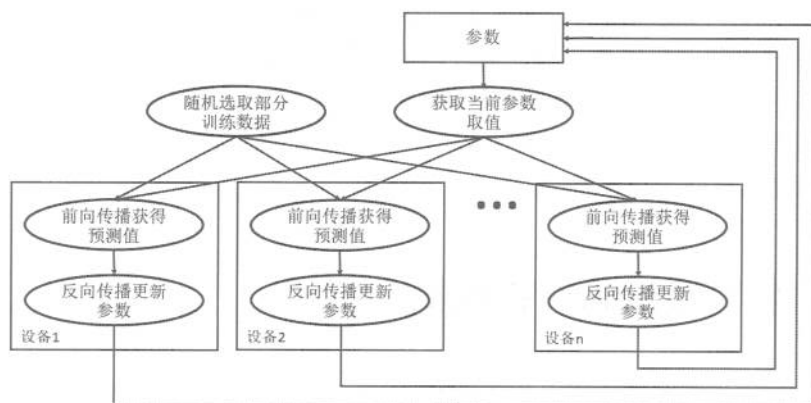


图 10-2 异步模式深度学习模型训练流程图

然而使用异步模式训练的深度学习模型有可能无法达到较优的训练结果。图 10-3 中给出了一个具体的样例来说明异步模式的问题。其中黑色曲线展示了模型的损失函数，黑色小球表示了 t_0 时刻参数所对应的损失函数的大小。假设两个设备 d_0 和 d_1 在时间 t_0 同时读取了参数的取值，那么设备 d_0 和 d_1 计算出来的梯度都会将小黑球向左移动。假设在时间 t_1 设备 d_0 已经完成了反向传播的计算并更新了参数，修改后的参数处于图 10-3 中小灰球的位置。然而这时的设备 d_1 并不知道参数已经被更新了，所以在时间 t_2 时，设备 d_1 会继续将小球向左移动，使得小球的位置达到图 10-3 中小白球的地方。从图 10-3 中可以看到，当参数被调整到小白球的位置时，将无法达到最优点。




图 10-3 异步模式训练深度学习模型存在的问题示意图

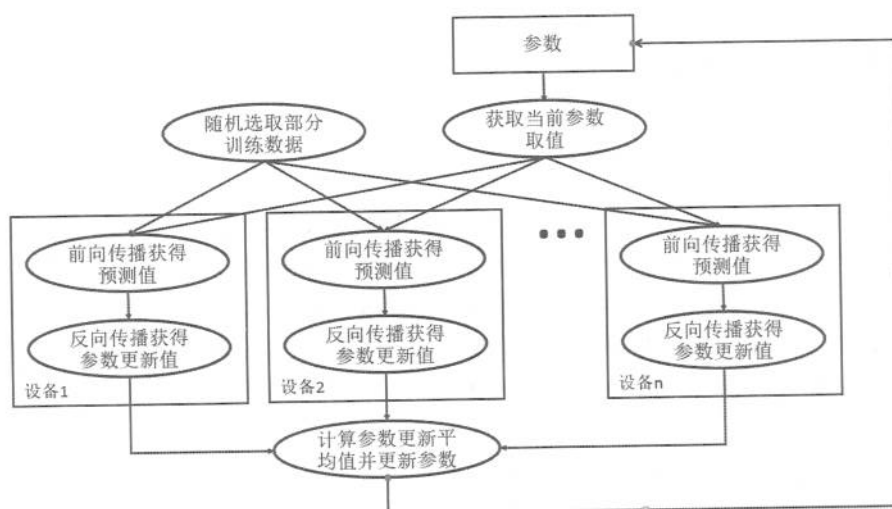


图 10-4 同步模式深度学习模型训练流程图

为了避免更新不同步的问题，可以使用同步模式。在同步模式下，所有的设备同时读取参数的取值，并且当反向传播算法完成之后同步更新参数的取值。单个设备不会单独对参数进行更新，而会等待所有设备都完成反向传播之后再统一更新参数^①。图 10-4 展示了

① 不同的算法实现会有略微的区别。TensorFlow 也支持更加灵活的同步更新方式使计算不会因为某个设备的故障而被卡住。而且在同步模式下，TensorFlow 会保证没有设备能使用陈旧的梯度更新模型中的参数。

同步模式的训练过程。从图 10-4 中可以看到，在每一轮迭代时，不同设备首先统一读取当前参数的取值，并随机获取一小部分数据。然后在不同设备上运行反向传播过程得到在各自训练数据上参数的梯度。注意虽然所有设备使用的参数是一致的，但是因为训练数据不同，所以得到参数的梯度就可能不一样。当所有设备完成反向传播的计算之后，需要计算出不同设备上参数梯度的平均值，最后再根据平均值对参数进行更新。

同步模式解决了异步模式中存在的参数更新问题，然而同步模式的效率却低于异步模式。在同步模式下，每一轮迭代都需要设备统一开始、统一结束。如果设备的运行速度不一致，那么每一轮训练都需要等待最慢的设备结束才能开始更新参数，于是很多时间将被花在等待上。虽然理论上异步模式存在缺陷，但因为训练深度学习模型时使用的随机梯度下降本身就是梯度下降的一个近似解法，而且即使是梯度下降也无法保证达到全局最优值，所以在实际应用中，在相同时间内，使用异步模式训练的模型不一定比同步模式差。所以这两种训练模式在实践中都有非常广泛的应用。

10.3 多 GPU 并行

在 10.2 节中介绍了常用的分布式深度学习模型训练模式。这一节将给出具体的 TensorFlow 代码，在一台机器的多个 GPU 上并行训练深度学习模型。因为一般来说一台机器上的多个 GPU 性能相似，所以在这种设置下会更多地采用同步模式训练深度学习模型。下面将给出具体的代码，在多 GPU 上训练深度学习模型解决 MNIST 问题。本节的样例代码将沿用 5.5 节中使用的代码框架，并且使用 5.5 节中给出的 `mnist_inference.py` 程序来完成神经网络的前向传播过程。以下代码给出了新的神经网络训练程序 `mnist_multi_gpu_train.py`。

```
# -*- coding: utf-8 -*-

from datetime import datetime
import os
import time

import tensorflow as tf
import mnist_inference

# 定义训练神经网络时需要用到的配置。这些配置与 5.5 节中定义的配置类似。
BATCH_SIZE = 100
LEARNING_RATE_BASE = 0.001
LEARNING_RATE_DECAY = 0.99
```

```

REGULARAZTION RATE = 0.0001
TRAINING_STEPS = 1000
MOVING_AVERAGE_DECAY = 0.99
N_GPU = 4

# 定义日志和模型输出的路径。
MODEL_SAVE_PATH = "/path/to/logs_and_models/"
MODEL_NAME = "model.ckpt"

# 定义数据存储的路径。因为需要为不同的 GPU 提供不同的训练数据，所以通过 placherholder
# 的方式就需要手动准备多份数据。为了方便训练数据的获取过程，可以采用第 7 章中介绍的输
# 入队列的方式从 TFRecord 中读取数据。于是在这里提供的数据文件路径为将 MNIST 训练数据
# 转化为 TFRecords 格式之后的路径。如何将 MNIST 数据转化为 TFRecord 格式在第 7 章中有
# 详细介绍，这里不再赘述。
DATA_PATH = "/path/to/data.tfrecords"

# 定义输入队列得到训练数据，具体细节可以参考第 7 章。
def get_input():
    filename_queue = tf.train.string_input_producer([DATA_PATH])
    reader = tf.TFRecordReader()
    _, serialized_example = reader.read(filename_queue)
    # 定义数据解析格式。
    features = tf.parse_single_example(
        serialized_example,
        features={
            'image_raw': tf.FixedLenFeature([], tf.string),
            'pixels': tf.FixedLenFeature([], tf.int64),
            'label': tf.FixedLenFeature([], tf.int64),
        })
    # 解析图片和标签信息。
    decoded_image = tf.decode_raw(features['image_raw'], tf.uint8)
    reshaped_image = tf.reshape(decoded_image, [784])
    retyped_image = tf.cast(reshaped_image, tf.float32)
    label = tf.cast(features['label'], tf.int32)

    # 定义输入队列并返回。
    min_after_dequeue = 10000
    capacity = min_after_dequeue + 3 * BATCH_SIZE
    return tf.train.shuffle_batch(
        [retyped_image, label],
        batch_size=BATCH_SIZE,
        capacity=capacity,
        min_after_dequeue=min_after_dequeue)

# 定义损失函数。对于给定的训练数据、正则化损失计算规则和命名空间，计算在这个命名空间
# 下的总损失。之所以需要给定命名空间是因为不同的 GPU 上计算得出的正则化损失都会加入名为

```

```

# loss 的集合，如果不通过命名空间就会将不同 GPU 上的正则化损失都加进来。
def get_loss(x, y_, regularizer, scope):
    # 沿用 5.5 节中定义的函数来计算神经网络的前向传播结果。
    y = mnist_inference.inference(x, regularizer)
    # 计算交叉熵损失。
    cross_entropy = tf.reduce_mean(
        tf.nn.sparse_softmax_cross_entropy_with_logits(y, y_))
    # 计算当前 GPU 上计算得到的正则化损失。
    regularization_loss = tf.add_n(tf.get_collection('losses', scope))
    # 计算最终的总损失。
    loss = cross_entropy + regularization_loss
    return loss

# 计算每一个变量梯度的平均值。
def average_gradients(tower_grads):
    average_grads = []
    # 枚举所有的变量和变量在不同 GPU 上计算得出的梯度。
    for grad_and_vars in zip(*tower_grads):
        # 计算所有 GPU 上的梯度平均值。
        grads = []
        for g, _ in grad_and_vars:
            expanded_g = tf.expand_dims(g, 0)
            grads.append(expanded_g)
        grad = tf.concat(0, grads)
        grad = tf.reduce_mean(grad, 0)

        v = grad_and_vars[0][1]
        grad_and_var = (grad, v)
        # 将变量和它的平均梯度对应起来。
        average_grads.append(grad_and_var)
    # 返回所有变量的平均梯度，这将被用于变量更新。
    return average_grads

# 主训练过程。
def main(argv=None):
    # 将简单的运算放在 CPU 上，只有神经网络的训练过程放在 GPU 上。
    with tf.Graph().as_default(), tf.device('/cpu:0'):
        # 获取训练 batch。
        x, y_ = get_input()
        regularizer = tf.contrib.layers.l2_regularizer(REGULARAZTION_RATE)

        # 定义训练轮数和指数衰减的学习率。
        global_step = tf.get_variable(
            'global_step', [], initializer=tf.constant_initializer(0),
            trainable=False)
        learning_rate = tf.train.exponential_decay(

```

```

LEARNING_RATE_BASE, global_step, 60000 / BATCH_SIZE,
LEARNING_RATE_DECAY)

# 定义优化方法。
opt = tf.train.GradientDescentOptimizer(learning_rate)

tower_grads = []
# 将神经网络的优化过程跑在不同的 GPU 上。
for i in range(N_GPU):
    # 将优化过程指定在一个 GPU 上。
    with tf.device('/gpu:%d' % i):
        with tf.name_scope('GPU_%d' % i) as scope:
            cur_loss = get_loss(x, y, regularizer, scope)
            # 在第一次声明变量之后, 将控制变量重用的参数设置为 True。这样可以
            # 让不同的 GPU 更新同一组参数。注意 tf.name_scope 函数并不会影响
            # tf.get_variable 的命名空间。
            tf.get_variable_scope().reuse_variables()

            # 使用当前 GPU 计算所有变量的梯度。
            grads = opt.compute_gradients(cur_loss)
            tower_grads.append(grads)

# 计算变量的平均梯度, 并输出到 TensorBoard 日志中。
grads = average_gradients(tower_grads)
for grad, var in grads:
    if grad is not None:
        tf.histogram_summary(
            'gradients_on_average/%s' % var.op.name, grad)

# 使用平均梯度更新参数。
apply_gradient_op = opt.apply_gradients(
    grads, global_step=global_step)
for var in tf.trainable_variables():
    tf.histogram_summary(var.op.name, var)

# 计算变量的滑动平均值。
variable_averages = tf.train.ExponentialMovingAverage(
    MOVING_AVERAGE_DECAY, global_step)
variables_averages_op = variable_averages.apply(
    tf.trainable_variables())

# 每一轮迭代需要更新变量的取值并更新变量的滑动平均值。
train_op = tf.group(apply_gradient_op, variables_averages_op)

saver = tf.train.Saver(tf.all_variables())

```

```
summary_op = tf.merge_all_summaries()
init = tf.initialize_all_variables()

# 训练过程。
with tf.Session(config=tf.ConfigProto(
    allow_soft_placement=True,
    log_device_placement=True)) as sess:
    # 初始化所有变量并启动队列。
    init.run()
    coord = tf.train.Coordinator()
    threads = tf.train.start_queue_runners(sess=sess, coord=coord)
    summary_writer = tf.train.SummaryWriter(
        MODEL_SAVE_PATH, sess.graph)

    for step in range(TRAINING_STEPS):
        # 执行神经网络训练操作，并记录训练操作的运行时间。
        start_time = time.time()
        _, loss_value = sess.run([train_op, cur_loss])
        duration = time.time() - start_time

        # 每隔一段时间展示当前的训练进度，并统计训练速度。
        if step != 0 and step % 10 == 0:
            # 计算使用过的训练数据个数。因为在每一次运行训练操作时，每一个 GPU
            # 都会使用一个 batch 的训练数据，所以总共用到的训练数据个数为
            # batch 大小×GPU 个数。
            num_examples_per_step = BATCH_SIZE * N_GPU

            # num_examples_per_step 为本次迭代使用到的训练数据个数，
            # duration 为运行当前训练过程使用的时间，于是平均每秒可以处理的训
            # 练数据个数为 num_examples_per_step / duration。
            examples_per_sec = num_examples_per_step / duration

            # duration 为运行当前训练过程使用的时间，因为在每一个训练过程中，
            # 每一个 GPU 都会使用一个 batch 的训练数据，所以在单个 batch 上的训
            # 练所需要时间为 duration / GPU 个数。
            sec_per_batch = duration / N_GPU

            # 输出训练信息。
            format_str = ('step %d, loss = %.2f (%.1f examples/ '
                           ' sec; %.3f sec/batch)')
            print(format_str % (step, loss_value,
                               examples_per_sec, sec_per_batch))

            # 通过 TensorBoard 可视化训练过程。
            summary = sess.run(summary_op)
            summary_writer.add_summary(summary, step)
```



```

# 每隔一段时间保存当前的模型。
if step % 1000 == 0 or (step + 1) == TRAINING_STEPS:
    checkpoint_path = os.path.join(
        MODEL_SAVE_PATH, MODEL_NAME)
    saver.save(sess, checkpoint_path, global_step=step)

coord.request_stop()
coord.join(threads)

if __name__ == '__main__':
    tf.app.run()
'''

```

在 AWS 的 g2.8xlarge 实例上运行上面这段程序可以得到类似下面的结果：

```

step 10, loss = 71.90 (15292.3 examples/sec; 0.007 sec/batch)
step 20, loss = 37.97 (18758.3 examples/sec; 0.005 sec/batch)
step 30, loss = 9.54 (16313.3 examples/sec; 0.006 sec/batch)
step 40, loss = 11.84 (14199.0 examples/sec; 0.007 sec/batch)
...
step 980, loss = 0.66 (15034.7 examples/sec; 0.007 sec/batch)
step 990, loss = 1.56 (16134.1 examples/sec; 0.006 sec/batch)
'''

```

在 AWS 的 g2.8xlarge 实例上运行以上代码可以同时使用 4 个 GPU 训练神经网络。图 10-5 显示了运行样例代码时不同 GPU 的使用情况。

Tue Nov 29 06:46:07 2016

NVIDIA-SMI 367.57 Driver Version: 367.57									
GPU	Name	Persistence-M	Bus-Id	Disp.A	Memory-Usage	Volatile Uncorr.	ECC	GPU-Util	Compute M.
Fan	Temp	Perf	Pwr:Usage/Cap			GPU-Util	Compute M.		
0	GRID K520	Off	0000:00:03.0	Off	3770MiB / 4036MiB	4%	N/A		Default
N/A	40C	P0	45W / 125W						
1	GRID K520	Off	0000:00:04.0	Off	3770MiB / 4036MiB	4%	N/A		Default
N/A	45C	P0	43W / 125W						
2	GRID K520	Off	0000:00:05.0	Off	3770MiB / 4036MiB	3%	N/A		Default
N/A	39C	P0	44W / 125W						
3	GRID K520	Off	0000:00:06.0	Off	3770MiB / 4036MiB	3%	N/A		Default
N/A	46C	P0	42W / 125W						
Processes:									
GPU	PID	Type	Process name	GPU Memory Usage					
0	2651	C	python	3768MiB					
1	2651	C	python	3768MiB					
2	2651	C	python	3768MiB					
3	2651	C	python	3768MiB					

图 10-5 在 AWS 的 g2.8xlarge 实例上运行 MNIST 样例程序时 GPU 的使用情况

因为在 5.5 节中定义的神经网络规模比较小,所以在图 10-5 中显示的 GPU 使用率不高。如果训练大型的神经网络模型, TensorFlow 将会占满所有用到的 GPU。

图 10-6 展示了通过 TensorBoard^①可视化得到的样例代码 TensorFlow 计算图,其中节点上的颜色代表了不同的设备,比如黑色代表 CPU、白色代表第一个 GPU,等等。从图 10-5 中可以看出,训练神经网络的主要过程被放到了 GPU_0、GPU_1、GPU_2 和 GPU_3 这 4 个模块中,而且每一个模块运行在一个 GPU 上。对比图 10-5 中的 TensorFlow 计算图可视化结果和图 10-4 中介绍的同步模式分布式深度学习训练流程图可以发现,这两个图的结构是非常接近的。




图 10-6 使用了 4 个 GPU 的 TensorFlow 计算图可视化结果

通过调整参数 `N_GPU`,可以实验同步模式下随着 GPU 个数的增加训练速度的加速比率。图 10-7 展示了在给出的 MNIST 样例代码上,训练速度随着 GPU 数量增加的变化趋势。从图 10-7 中可以看出,当使用两个 GPU 时,模型的训练速度是使用一个 GPU 的 1.92 倍。也就是说当 GPU 数量较小时,训练速度基本可以随着 GPU 的数量线性增长。图 10-8 展示了当 GPU 数量增多时,训练速度随着 GPU 数量增加的加速比。从图 10-8 中可以看出,当 GPU 数量增加时,虽然加速比不再是线性,但 TensorFlow 仍然可以通过增加 GPU 数量有效地加速深度学习模型的训练过程。

^① TensorBoard 在第 9 章中有详细介绍。




图 10-7 训练速度随着 GPU 数量增加的变化趋势
(此数据是通过 MNIST 样例代码在 AWS 的 g2.8xlarge 实例上测试得到的)




图 10-8 训练速度随着 GPU 数量增加的变化趋势，此数据来自谷歌官方的测试结果^①

10.4 分布式 TensorFlow

通过多 GPU 并行的方式可以达到很好的加速效果。然而一台机器上能够安装的 GPU 有限，要进一步提升深度学习模型的训练速度，就需要将 TensorFlow 分布式运行在多台机器上。本节将介绍如何编写以及运行分布式 TensorFlow 的程序。首先，在 10.4.1 小节中将介绍分布式 TensorFlow 的工作原理，并给出最简单的分布式 TensorFlow 样例程序。在这一小节中也将介绍不同的 TensorFlow 分布式方式。然后，在 10.4.2 小节中将给出两个完整的 TensorFlow 样例程序来同步或者异步地训练深度学习模型。最后，在 10.4.3 小节中将总结目前原生态分布式 TensorFlow 中的不足，并介绍才云科技（Caicloud.io）提供的分布式 TensorFlow 解决方案（TensorFlow as a Service, TaaS）。

① 具体结果可以参考谷歌官方技术博客：<https://research.googleblog.com/2016/04/announcing-tensorflow-08-now-with.html>。

10.4.1 分布式 TensorFlow 原理

在 10.2 节中介绍了分布式 TensorFlow 训练深度学习模型的理论。本小节将具体介绍如何使用 TensorFlow 在分布式集群中训练深度学习模型。以下代码展示了如何创建一个最简单的 TensorFlow 集群：

```
import tensorflow as tf
c = tf.constant("Hello, distributed TensorFlow!")
# 创建一个本地 TensorFlow 集群
server = tf.train.Server.create_local_server()
# 在集群上创建一个会话。
sess = tf.Session(server.target)
# 输出 Hello, distributed TensorFlow!
print sess.run(c)
```

在以上代码中，首先通过 `tf.train.Server.create_local_server` 函数在本地建立了一个只有一台机器的 TensorFlow 集群。然后在该集群上生成了一个会话，并通过生成的会话将运算运行在创建的 TensorFlow 集群上。虽然这只是一个单机集群，但它大致反应了 TensorFlow 集群的工作流程。TensorFlow 集群通过一系列的任务（tasks）来执行 TensorFlow 计算图中的运算。一般来说，不同任务跑在不同机器上。最主要的例外是使用 GPU 时，不同任务可以使用同一台机器上的不同 GPU。TensorFlow 集群中的任务也会被聚合成工作（jobs），每个工作可以包含一个或者多个任务。比如在训练深度学习模型时，一台运行反向传播的机器是一个任务，而所有运行反向传播机器的集合是一种工作。

上面的样例代码是只有一个任务的集群。当一个 TensorFlow 集群有多个任务时，需要使用 `tf.train.ClusterSpec` 来指定运行每一个任务的机器。比如以下代码展示了在本地运行有两个任务的 TensorFlow 集群。第一个任务的代码如下：

```
import tensorflow as tf
c = tf.constant("Hello from server1!")

# 生成一个有两个任务的集群，一个任务跑在本地 2222 端口，另外一个跑在本地 2223 端口。
cluster = tf.train.ClusterSpec(
    {"local": ["localhost:2222", "localhost:2223"]})
# 通过上面生成的集群配置生成 Server，并通过 job_name 和 task_index 指定当前所启动
# 的任务。因为该任务是第一个任务，所以 task_index 为 0。
server = tf.train.Server(cluster, job_name="local", task_index=0)

# 通过 server.target 生成会话来使用 TensorFlow 集群中的资源。通过设置
# log_device_placement 可以看到执行每一个操作的任务。
sess = tf.Session()
```

```
server.target, config=tf.ConfigProto(log_device_placement=True))
print sess.run(c)
server.join()
```

下面给出了第二个任务的代码：

```
import tensorflow as tf
c = tf.constant("Hello from server2!")

# 和第一个程序一样的集群配置。集群中的每一个任务需要采用相同的配置。
cluster = tf.train.ClusterSpec(
    {"local": ["localhost:2222", "localhost: 2223"]})
# 指定 task_index 为 1，所以这个程序将在 localhost:2223 启动服务。
server = tf.train.Server(cluster, job_name="local", task_index=1)
# 剩下的代码都和第一个任务的代码一致。
...
```

启动第一个任务后，可以得到类似下面的输出：

```
I tensorflow/core/distributed_runtime/rpc/grpc_channel.cc:206] Initialize
HostPortsGrpcChannelCache for job local -> {localhost:2222, localhost:2223}
I tensorflow/core/distributed_runtime/rpc/grpc_server_lib.cc:202] Started
server with target: grpc://localhost:2222
E1123 08:26:06.824503525 12232 tcp_client_posix.c:173] failed to
connect to 'ipv4:127.0.0.1:2223': socket error: connection refused
E1123 08:26:08.825022513 12232 tcp_client_posix.c:173] failed to
connect to 'ipv4:127.0.0.1:2223': socket error: connection refused
I tensorflow/core/common_runtime/simple_placer.cc:818] Const: /job:local/
replica:0/task:0/cpu:0
Const: /job:local/replica:0/task:0/cpu:0
Hello from server1!
```

从第一个任务的输出中可以看到，当只启动第一个任务时，程序会停下来等待第二个任务启动，而且持续输出 `failed to connect to 'ipv4:127.0.0.1:2223': socket error: connection refused`。当第二个任务启动后，可以看到从第一个任务中会输出 `Hello from server1!` 的结果。第二个任务的输出如下：

```
I tensorflow/core/distributed_runtime/rpc/grpc_channel.cc:206] Initialize
HostPortsGrpcChannelCache for job local -> {localhost:2222, localhost:2223}
I tensorflow/core/distributed_runtime/rpc/grpc_server_lib.cc:202] Started
server with target: grpc://localhost:2223
Const: /job:local/replica:0/task:0/cpu:0
I tensorflow/core/common_runtime/simple_placer.cc:818] Const: /job:local/
replica:0/task:0/cpu:0
Hello from server2!
```

值得注意的是第二个任务中定义的计算也被放在了设备/job:local/replica:0/task:0/cpu:0上。也就是说这个计算将由第一个任务来执行。从上面这个样例可以看到,通过tf.train.Server.target生成的会话可以统一管理整个TensorFlow集群中的资源。

和使用多GPU类似,TensorFlow支持通过tf.device来指定操作运行在哪个任务上。比如将第二个任务中定义计算的语句改为以下代码,就可以看到这个计算将被调度到/job:local/replica:0/task:1/cpu:0上面。

```
with tf.device("/job:local/task:1"):
    c = tf.constant("Hello from server2!")
```

在上面的样例中只定义了一个工作“local”。但一般在训练深度学习模型时,会定义两个工作。一个工作专门负责存储、获取以及更新变量的取值,这个工作所包含的任务统称为参数服务器(parameter server, ps)。另外个工作负责运行反向传播算法来获取参数梯度,这个工作所包含的任务统称为计算服务器(worker)。下面给出了一个比较常见的用于训练深度学习模型的TensorFlow集群配置方法。

```
tf.train.ClusterSpec({
    "worker": [
        "tf-worker0:2222",
        "tf-worker1:2222",
        "tf-worker2:2222"
    ],
    "ps": [
        "tf-ps0:2222",
        "tf-ps1:2222"
    ]})①
```

使用分布式TensorFlow训练深度学习模型一般有两种方式。一种方式叫做计算图内分布式(in-graph replication)。使用这种分布式训练方式时,所有的任务都会使用一个TensorFlow计算图中的变量(也就是深度学习模型中的参数),而只是将计算部分发布到不同的计算服务器上。10.3节中给出的使用多GPU样例程序就是这种方式。多GPU样例程序将计算复制了多份,每一份放到一个GPU上进行运算。但不同的GPU使用的参数都是在一个TensorFlow计算图中的。因为参数都是存在同一个计算图中,所以同步更新参数比较容易控制。在10.3节中给出的代码也实现了参数的同步更新。然而因为计算图内分布式需要有一个中心节点来生成这个计算图并分配计算任务,所以当数据量太大时,这个中心节点容易造成性能瓶颈。

另外一种分布式TensorFlow训练深度学习模型的方式叫计算图之间分布式

^① 注意这里给出的tf-worker(i)和tf-ps(i)都是服务器地址。

(between-graph replication)。使用这种分布式方式时，在每一个计算服务器上都会创建一个独立的 TensorFlow 计算图，但不同计算图中的相同参数需要以一种固定的方式放到同一个参数服务器上。TensorFlow 提供了 `tf.train.replica_device_setter` 函数来帮助完成这一个过程，在 10.4.2 小节中将给出具体的样例。因为每个计算服务器的 TensorFlow 计算图是独立的，所以这种方式的并行度要更高。但在计算图之间分布式下进行参数的同步更新比较困难。为了解决这个问题，TensorFlow 提供了 `tf.train.SyncReplicasOptimizer` 函数来帮助实现参数的同步更新。这让计算图之间分布式方式被更加广泛地使用。在 10.4.2 小节中将给出使用计算图之间分布式的样例程序来实现异步模式和同步模式的并行化深度学习模型训练过程。

10.4.2 分布式 TensorFlow 模型训练

本小节中将给出两个样例程序分别实现使用计算图之间分布式（Between-graph replication）完成分布式深度学习模型训练的异步更新和同步更新。第一部分将给出使用计算图之间分布式实现异步更新的 TensorFlow 程序。这一部分也会给出具体的命令行将该程序分布式的运行在一个参数服务器和两个计算服务器上，并通过 TensorBoard 可视化在第一个计算服务器上的 TensorFlow 计算图。第二部分将给出计算图之间分布式实现同步参数更新的 TensorFlow 程序。同步参数更新的代码大部分和异步更新相似，所以在这一部分中将重点介绍它们之间的不同之处。

异步模式样例程序

下面的样例代码将仍然采用 5.5 节中给出的模式，并复用 5.5 节 `mnist_inference.py` 程序中定义的前向传播算法。以下代码实现了异步模式的分布式神经网络训练过程。

```
# -*- coding: utf-8 -*-

import time
import tensorflow as tf
from tensorflow.examples.tutorials.mnist import input_data

import mnist_inference

# 和 5.5 节中类似的配置神经网络的设置。
BATCH_SIZE = 100
LEARNING_RATE_BASE = 0.01
LEARNING_RATE_DECAY = 0.99
REGULARAZTION_RATE = 0.0001
TRAINING_STEPS = 10000
# 模型保存的路径。
```



```

MODEL_SAVE_PATH = "/path/to/model"
# MNIST 数据路径。
DATA_PATH = "/path/to/data"

# 通过 flags 指定运行的参数。在 10.4.1 小节中对于不同的任务 (task) 给出了不同的程序,
# 但这不是一种可扩展的方式。在这一小节中将使用运行程序时给出的参数来配置在不同
# 任务中运行的程序。
FLAGS = tf.app.flags.FLAGS

# 指定当前运行的是参数服务器还是计算服务器。参数服务器只负责 TensorFlow 中变量的维护
# 和管理, 计算服务器负责每一轮迭代时运行反向传播过程。
tf.app.flags.DEFINE_string('job_name', 'worker', ' "ps" or "worker" ')

# 指定集群中的参数服务器地址。
tf.app.flags.DEFINE_string(
    'ps_hosts', ' tf-ps0:2222,tf-ps1:1111',
    'Comma-separated list of hostname:port for the parameter server jobs. '
    'e.g. "tf-ps0:2222,tf-ps1:1111" ')

# 指定集群中的计算服务器地址。
tf.app.flags.DEFINE_string(
    'worker_hosts', ' tf-worker0:2222,tf-worker1:1111',
    'Comma-separated list of hostname:port for the worker jobs. '
    'e.g. "tf-worker0:2222,tf-worker1:1111" ')

# 指定当前程序的任务 ID。TensorFlow 会自动根据参数服务器/计算服务器列表中的端口号
# 来启动服务。注意参数服务器和计算服务器的编号都是从 0 开始的。
tf.app.flags.DEFINE_integer(
    'task_id', 0, 'Task ID of the worker/replica running the training.')

# 定义 TensorFlow 的计算图, 并返回每一轮迭代时需要运行的操作。这个过程和 5.5 节中的主
# 函数基本一致, 但为了使处理分布式计算的部分更加突出, 本小节将此过程整理为一个函数。
def build_model(x, y, is_chief):
    regularizer = tf.contrib.layers.l2_regularizer(REGULARAZTION_RATE)
    # 通过和 5.5 节给出的 mnist_inference.py 代码计算神经网络前向传播的结果。
    y = mnist_inference.inference(x, regularizer)
    global_step = tf.Variable(0, trainable=False)

    # 计算损失函数并定义反向传播过程。
    cross_entropy = tf.nn.sparse_softmax_cross_entropy_with_logits(
        y, tf.argmax(y, 1))
    cross_entropy_mean = tf.reduce_mean(cross_entropy)
    loss = cross_entropy_mean + tf.add_n(tf.get_collection('losses'))
    learning_rate = tf.train.exponential_decay(

```

```

        LEARNING_RATE_BASE, global_step, 60000 / BATCH_SIZE,
        LEARNING_RATE_DECAY)

# 定义每一轮迭代需要运行的操作。
train_op = tf.train.GradientDescentOptimizer(learning_rate)\
    .minimize(loss, global_step=global_step)
return global_step, loss, train_op

# 训练分布式深度学习模型的主过程。
def main(argv=None):
    # 解析 flags 并通过 tf.train.ClusterSpec 配置 TensorFlow 集群。
    ps_hosts = FLAGS.ps_hosts.split(',')
    worker_hosts = FLAGS.worker_hosts.split(',')
    cluster = tf.train.ClusterSpec({"ps": ps_hosts, "worker": worker_hosts})
    # 通过 ClusterSpec 以及当前任务创建 Server。
    server = tf.train.Server(
        cluster, job_name=FLAGS.job_name, task_index=FLAGS.task_id)

    # 参数服务器只需要管理 TensorFlow 中的变量，不需要执行训练的过程。server.join()
    # 会一直停在这条语句上。
    if FLAGS.job_name == 'ps':
        server.join()

    # 定义计算服务器需要运行的操作。在所有的计算服务器中有一个是主计算服务器，它除了负责
    # 计算反向传播的结果，它还负责输出日志和保存模型。
    is_chief = (FLAGS.task_id == 0)
    mnist = input_data.read_data_sets(DATA_PATH, one_hot=True)

    # 通过 tf.train.replica_device_setter 函数来指定执行每一个运算的设备。
    # tf.train.replica_device_setter 函数会自动将所有的参数分配到参数服务器上，而
    # 计算分配到当前的计算服务器上。图 10-9 展示了通过 TensorBoard 可视化得到的第一个计
    # 算服务器上运算分配的结果。
    with tf.device(tf.train.replica_device_setter(
        worker_device="/job:worker/task:%d" % FLAGS.task_id,
        cluster=cluster)):
        x = tf.placeholder(
            tf.float32, [None, mnist_inference.INPUT_NODE],
            name='x-input')
        y_ = tf.placeholder(
            tf.float32, [None, mnist_inference.OUTPUT_NODE],
            name='y-input')
        # 定义训练模型需要运行的操作。
        global_step, loss, train_op = build_model(x, y_)

```

```

# 定义用于保存模型的 saver。
saver = tf.train.Saver()
# 定义日志输出操作。
summary_op = tf.merge_all_summaries()
# 定义变量初始化操作。
init_op = tf.initialize_all_variables()
# 通过 tf.train.Supervisor 管理训练深度学习模型的通用功能。
# tf.train.Supervisor 能统一管理队列操作、模型保存、日志输出以及会话的生成。
sv = tf.train.Supervisor(
    is_chief=is_chief,          # 定义当前计算服务器是否为主计算服务器，只有
                                # 主计算服务器会保存模型以及输出日志。
    logdir=MODEL_SAVE_PATH,    # 指定保存模型和输出日志的地址。
    init_op=init_op,           # 指定初始化操作。
    summary_op=summary_op,      # 指定日志生成操作。
    saver = saver,              # 指定用于保存模型的 saver。
    global_step=global_step,    # 指定当前迭代的轮数，这个会用于生成保存模
                                # 型文件的文件名。
    save_model_secs=60,         # 指定保存模型的时间间隔。
    save_summaries_secs=60)    # 指定日志输出的时间间隔。

sess_config = tf.ConfigProto(allow_soft_placement=True,
                              log_device_placement=False)
# 通过 tf.train.Supervisor 生成会话。
sess = sv.prepare_or_wait_for_session(
    server.target, config=sess_config)

step = 0
start_time = time.time()
# 执行迭代过程。在迭代过程中 tf.train.Supervisor 会帮助输出日志并保存模型，
# 所以不需要直接调用这些过程。
while not sv.should_stop():
    xs, ys = mnist.train.next_batch(BATCH_SIZE)
    _, loss_value, global_step_value = sess.run(
        [train_op, loss, global_step], feed_dict={x: xs, y: ys})
    if global_step_value >= TRAINING_STEPS: break

    # 每隔一段时间输出训练信息。
    if step > 0 and step % 100 == 0:
        duration = time.time() - start_time
        # 不同的计算服务器都会更新全局的训练轮数，所以这里使用
        # global_step_value 可以直接得到在训练中使用过的 batch 的总数。
        sec_per_batch = duration / global_step_value

```

```

        format_str = ("After %d training steps (%d global steps), "
                      "loss on training batch is %g. "
                      "(%.3f sec/batch)")
        print(format_str % (step, global_step_value,
                           loss_value, sec_per_batch))

        step += 1
    sv.stop()

if __name__ == "__main__":
    tf.app.run()

```

假设上面代码的文件名为 `dist_tf_mnist_async.py`，那么要启动一个拥有一个参数服务器、两个计算服务器的集群，需要先在运行参数服务器的机器上启动以下命令：

```

python dist_tf_mnist_async.py \
--job_name='ps' \
--task_id=0 \
--ps_hosts='tf-ps0:2222' \
--worker_hosts='tf-worker0:2222,tf-worker1:2222'

```

然后在运行第一个计算服务器的机器上启动以下命令：

```

python dist_tf_mnist_async.py \
--job_name='worker' \
--task_id=0 \
--ps_hosts='tf-ps0:2222' \
--worker_hosts='tf-worker0:2222,tf-worker1:2222'

```

最后在运行第二个计算服务器的机器上启动以下命令：

```

python dist_tf_mnist_async.py \
--job_name='worker' \
--task_id=1 \
--ps_hosts='tf-ps0:2222' \
--worker_hosts='tf-worker0:2222,tf-worker1:2222'

```

在启动第一个计算服务器之后，这个计算服务器就会尝试连接其他的服务器（包括计算服务器和参数服务器）。如果其他服务器还没有启动，则被启动的计算服务器会报连接出错的问题。下面展示了一个出错信息。

```

E1201 01:26:04.166203632 21402 tcp_client_posix.c:173] failed to
connect to 'ipv4:tf-worker1:2222': socket error: connection refused

```

不过这不会影响 TensorFlow 集群的启动。当 TensorFlow 集群中所有服务器都被启动之后，每一个计算服务器将不再报错。在 TensorFlow 集群完全启动之后，训练过程将被执行。

TensorFlow: 实战 Google 深度学习框架

图 10-9 展示了第一个计算服务器的 TensorFlow 计算图。从图 10-9 中可以看出，神经网络中定义参数被放在了参数服务器上（图中浅灰色节点），而反向传播的计算过程则放在了当前的计算服务器上（图中的深灰色节点）。

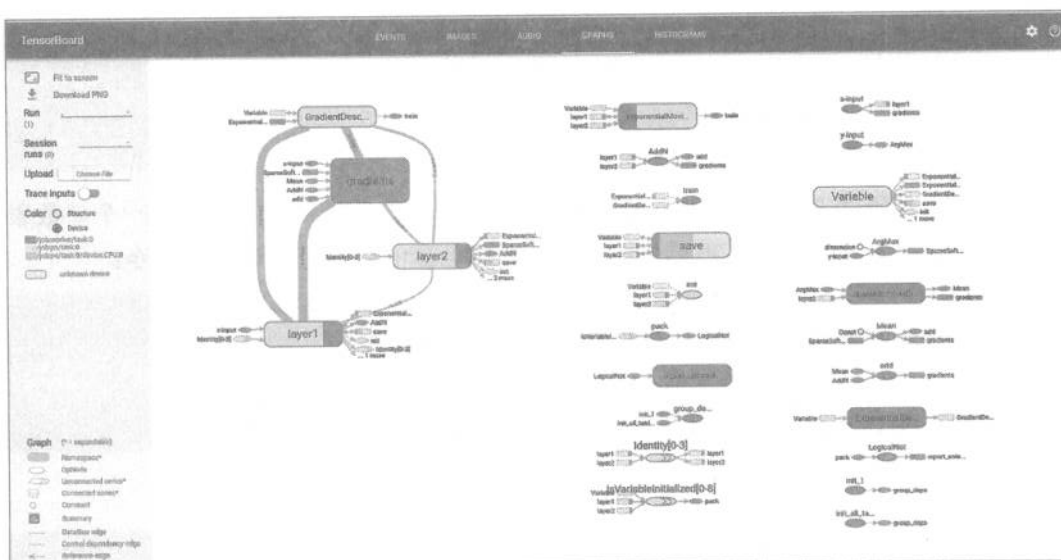


图 10-9 通过 TensorBoard 可视化的分布式 TensorFlow 计算图

在计算服务器训练神经网络的过程中，第一个计算服务器会输出类似下面的信息。

```
After 100 training steps (100 global steps), loss on training batch is
0.302718. (0.039 sec/batch)
After 200 training steps (200 global steps), loss on training batch is
0.269476. (0.037 sec/batch)
After 300 training steps (300 global steps), loss on training batch is
0.286755. (0.037 sec/batch)
After 400 training steps (463 global steps), loss on training batch is
0.349983. (0.033 sec/batch)
After 500 training steps (666 global steps), loss on training batch is
0.229955. (0.029 sec/batch)
After 600 training steps (873 global steps), loss on training batch is
0.245588. (0.027 sec/batch)
```

第二个计算服务器会输出类似下面的信息。

```
After 100 training steps (537 global steps), loss on training batch is
0.223165. (0.007 sec/batch)
After 200 training steps (732 global steps), loss on training batch is
```

```
0.186126. (0.010 sec/batch)
After 300 training steps (925 global steps), loss on training batch is
0.228191. (0.012 sec/batch)
```

从输出的信息中可以看到，在第二个计算服务器启动之前，第一个计算服务器已经运行了很多轮迭代了。在异步模式下，即使有计算服务器没有正常工作，参数更新的过程仍可继续，而且全局的迭代轮数是所有计算服务器迭代轮数的和。

同步模式样例程序

和异步模式类似，下面给出的代码同样也是基于 5.5 小节中给出的框架。该代码实现了同步模式的分布式神经网络训练过程。

```
# -*- coding: utf-8 -*-

import time
import tensorflow as tf
from tensorflow.examples.tutorials.mnist import input_data

import mnist_inference

BATCH_SIZE = 100
LEARNING_RATE_BASE = 0.8
LEARNING_RATE_DECAY = 0.99
REGULARAZTION_RATE = 0.0001
TRAINING_STEPS = 10000
MODEL_SAVE_PATH = "/path/to/model"
DATA_PATH = "/path/to/data"

# 和异步模式类似的设置 flags。
FLAGS = tf.app.flags.FLAGS

tf.app.flags.DEFINE_string('job_name', 'worker', ' "ps" or "worker" ')
tf.app.flags.DEFINE_string(
    'ps_hosts', ' tf-ps0:2222,tf-ps1:1111',
    'Comma-separated list of hostname:port for the parameter server jobs. '
    'e.g. "tf-ps0:2222,tf-ps1:1111" ')

tf.app.flags.DEFINE_string(
    'worker_hosts', ' tf-worker0:2222,tf-worker1:1111',
    'Comma-separated list of hostname:port for the worker jobs. '
    'e.g. "tf-worker0:2222,tf-worker1:1111" ')

tf.app.flags.DEFINE_integer(
```



```

    'task_id', 0, 'Task ID of the worker/replica running the training.')

# 和异步模式类似地定义 TensorFlow 的计算图。唯一的区别在于使用
# tf.train.SyncReplicasOptimizer 函数处理同步更新。
def build_model(x, y_, n_workers, is_chief):
    regularizer = tf.contrib.layers.l2_regularizer(REGULARAZTION_RATE)
    y = mnist_inference.inference(x, regularizer)
    global_step = tf.Variable(0, trainable=False)

    variable_averages = tf.train.ExponentialMovingAverage(
        MOVING_AVERAGE_DECAY, global_step)
    variables_averages_op = variable_averages.apply(tf.trainable_variables())

    cross_entropy = tf.nn.sparse_softmax_cross_entropy_with_logits(
        y, tf.argmax(y_, 1))
    cross_entropy_mean = tf.reduce_mean(cross_entropy)
    loss = cross_entropy_mean + tf.add_n(tf.get_collection('losses'))
    learning_rate = tf.train.exponential_decay(
        LEARNING_RATE_BASE, global_step, 60000 / BATCH_SIZE,
        LEARNING_RATE_DECAY)

    # 通过 tf.train.SyncReplicasOptimizer 函数实现同步更新。
    opt = tf.train.SyncReplicasOptimizer(
        # 定义基础的优化方法。
        tf.train.GradientDescentOptimizer(learning_rate),
        # 定义每一轮更新需要多少个计算服务器得出的梯度。
        replicas_to_aggregate=n_workers,
        # 指定总共有多少个计算服务器。
        total_num_replicas=n_workers,
        # 指定当前计算服务器的编号。
        replica_id=FLAGS.task_id)

    train_op = opt.minimize(loss, global_step=global_step)
    return global_step, loss, train_op, opt

def main(argv=None):
    # 和异步模式类似地创建 TensorFlow 集群。
    ps_hosts = FLAGS.ps_hosts.split(',')
    worker_hosts = FLAGS.worker_hosts.split(',')
    n_workers = len(worker_hosts)

    cluster = tf.train.ClusterSpec({"ps": ps_hosts, "worker": worker_hosts})
    server = tf.train.Server(
        cluster, job_name = FLAGS.job_name, task_index=FLAGS.task_id)

```

```

if FLAGS.job_name == 'ps':
    server.join()

is_chief = (FLAGS.task_id == 0)
mnist = input_data.read_data_sets(DATA_PATH, one_hot=True)

with tf.device(tf.train.replica_device_setter(
    worker_device="/job:worker/task:%d" % FLAGS.task_id,
    cluster=cluster)):
    x = tf.placeholder(
        tf.float32, [None, mnist_inference.INPUT_NODE],
        name='x-input')
    y_ = tf.placeholder(
        tf.float32, [None, mnist_inference.OUTPUT_NODE],
        name='y-input')
    global_step, loss, train_op, opt = build_model(
        x, y_, n_workers, is_chief)

    saver = tf.train.Saver()
    summary_op = tf.merge_all_summaries()
    init_op = tf.initialize_all_variables()

# 在同步模式下，主计算服务器需要协调不同计算服务器计算得到的参数梯度并最终更新
# 参数。这需要主计算服务器完成一些额外的初始化工作。
if is_chief:
    # 定义协调不同计算服务器的队列并定义初始化操作。
    chief_queue_runner = opt.get_chief_queue_runner()
    init_tokens_op = opt.get_init_tokens_op(0)

# 和异步模式类似的声明 tf.train.Supervisor。
sv = tf.train.Supervisor(is_chief=is_chief,
                        logdir=MODEL_SAVE_PATH,
                        init_op=init_op,
                        summary_op=summary_op,
                        saver=saver,
                        global_step=global_step,
                        save_model_secs=60,
                        save_summaries_secs=60)
sess_config = tf.ConfigProto(allow_soft_placement=True,
                             log_device_placement=False)
sess = sv.prepare_or_wait_for_session(
    server.target, config=sess_config)

```

```

# 在开始训练模型之前，主计算服务器需要启动协调同步更新的队列并执行初始化操作。
if is_chief:
    sv.start_queue_runners(sess, [chief_queue_runner])
    sess.run(init_tokens_op)

# 和异步模式类似的运行迭代的训练过程。
step = 0
start_time = time.time()
while not sv.should_stop():
    xs, ys = mnist.train.next_batch(BATCH_SIZE)
    _, loss_value, global_step_value = sess.run(
        [train_op, loss, global_step], feed_dict={x: xs, y: ys})
    if global_step_value >= TRAINING_STEPS: break

    if step > 0 and step % 100 == 0:
        duration = time.time() - start_time
        sec_per_batch = duration / (global_step_value * n_workers)
        format_str = ("After %d training steps (%d global steps), "
                      "loss on training batch is %g. "
                      "(%.3f sec/batch)")
        print(format_str % (step, global_step_value,
                           loss_value, sec_per_batch))

    step += 1
sv.stop()

if __name__ == "__main__":
    tf.app.run()

```

和异步模式类似，在不同机器上运行以上代码就可以启动 TensorFlow 集群。但和异步模式不同的是，当第一台计算服务器初始化完毕之后，它并不能直接更新参数。这是因为在程序中要求每一次参数更新都需要来自两个计算服务器的梯度。在第一个计算服务器上，可以看到与下面类似的输出。

```

E1201 01:26:04.166203632 21402 tcp_client_posix.c:173] failed to
connect to 'ipv4:10.57.60.76:2222': socket error: connection refused
After 100 training steps (100 global steps), loss on training batch is
1.88782. (0.176 sec/batch)
After 200 training steps (200 global steps), loss on training batch is
0.834916. (0.101 sec/batch)
...
After 800 training steps (800 global steps), loss on training batch is
0.524181. (0.045 sec/batch)
After 900 training steps (900 global steps), loss on training batch is
0.384861. (0.042 sec/batch)

```

第二个计算服务器的输出如下：

```
After 100 training steps (100 global steps), loss on training batch is
1.88782. (0.028 sec/batch)
After 200 training steps (200 global steps), loss on training batch is
0.834916. (0.027 sec/batch)
...
After 800 training steps (800 global steps), loss on training batch is
0.474765. (0.026 sec/batch)
After 900 training steps (900 global steps), loss on training batch is
0.420769. (0.026 sec/batch)
```

在第一个计算服务器的第一行输出中可以看到，前 100 轮迭代的平均速度为 0.176 sec/batch，要远远慢于最后的平均速度 0.042 sec/batch。这是因为在第一迭代轮开始之前，第一个计算服务器需要等待第二个计算服务器执行初始化的过程，于是导致前 100 轮迭代的平均速度是最慢的。这也反应了同步更新的一个问题。当一个计算服务器被卡住时，其他所有的计算服务器都需要等待这个最慢的计算服务器。

为了解决这个问题，可以调整 `tf.train.SyncReplicasOptimizer` 函数中的 `replicas_to_aggregate` 参数。当 `replicas_to_aggregate` 小于计算服务器总数时，每一轮迭代就不需要收集所有的梯度，从而避免被最慢的计算服务器卡住。TensorFlow 也支持通过调整同步队列初始化操作 `tf.train.SyncReplicasOptimizer.get_init_tokens_op` 中的参数来控制对不同计算服务器之间的同步要求。当提供给初始化函数 `get_init_tokens_op` 的参数大于 0 时，TensorFlow 支持多次使用由同一个计算服务器得到的梯度，于是也可以缓解计算服务器性能瓶颈的问题。

10.4.3 使用 Caicloud 运行分布式 TensorFlow

从 10.4.2 小节中给出的样例程序可以看出，每次运行分布式 TensorFlow 都需要登录不同的机器来启动集群。这使得使用起来非常不方便。当需要使用 100 台机器运行分布式 TensorFlow 时，需要手动登录到每一台机器并启动 TensorFlow 服务，这个过程十分烦琐。而且，当某个服务器上的程序死掉之后，TensorFlow 并不能自动重启，这给监控工作带来了巨大的难度。如果类比 TensorFlow 与 Hadoop^①，可以发现 TensorFlow 只实现了相当于 Hadoop 中 MapReduce 的计算框架，而没有提供类似 Yarn 的集群管理工具以及 HDFS 的存储系统。为了降低分布式 TensorFlow 的使用门槛，才云科技(Caicloud.io)基于 Kubernetes^②容

① 更多关于 Hadoop 的介绍可以参考其官方网站：<http://hadoop.apache.org/>。

② 更多关于 Kubernetes 的介绍可以参考其官方网站：<http://kubernetes.io/>。

器云平台提供了一个分布式 TensorFlow 平台 TensorFlow as a Service (TaaS)^①。本节中将大致介绍如何使用 Caicloud 提供的 TaaS 平台运行分布式 TensorFlow。

从 10.4.2 小节中给出的代码可以看出,编写分布式 TensorFlow 程序需要指定很多与模型训练无关的代码来完成 TensorFlow 集群的设置工作。为了降低分布式 TensorFlow 的学习成本,Caicloud 的 TensorFlow as a Service (TaaS) 平台首先对 TensorFlow 集群进行了更高层的封装,屏蔽了其中与模型训练无关的底层细节。其次,TaaS 平台结合了谷歌开源的容器云平台管理工具 Kubernetes 来实现对分布式 TensorFlow 任务的管理和监控,并支持通过 UI 设置分布式 TensorFlow 任务的节点个数、是否使用 GPU 等信息。

Caicloud 的 TaaS 平台提供了一个抽象基类 CaicloudDistTensorflowBase,该类封装了分布式 TensorFlow 集群的配置与启动、模型参数共享与更新逻辑处理、计算节点之间的协同交互以及训练得到的模型和日志的保存等与模型训练过程无关的操作。用户只需要继承该基类,并实现与模型训练相关的函数即可。其代码结构如下:

```
import caicloud_dist_tensorflow_base as caicloud
class MyDistTfModel(caicloud.CaicloudDistTensorflowBase):
    """基于自身业务来定义训练模型、执行训练操作等"""
```

用户继承的类需要选择性地实现 CaicloudDistTensorflowBase 基类中的 4 个函数,它们分别是 build_model、get_init_fn、train 和 after_train。build_model 给出了定义 TensorFlow 计算图的接口。在这个函数中,用户需要处理输入数据、定义深度学习模型以及定义训练模型的过程。get_init_fn 函数中可以定义在会话(tf.Session)生成之后需要额外完成的初始化工作,当没有特殊的初始化操作时,用户可以不用定义这个函数。这个函数可以完成模型预加载的过程。train 函数中定义的是每一轮训练中需要运行的操作。TaaS 会自动完成迭代的过程,但用户需要定义每一轮迭代中需要执行的操作。最后在训练结束之后,用户可以通过定义 after_train 来评测以及保存最后得到的模型。下面将通过 TaaS 平台实现分布式 TensorFlow 训练过程来解决 MNIST 问题^②。

```
import tensorflow as tf
from tensorflow.examples.tutorials.mnist import input_data
import caicloud_dist_tensorflow_base as caicloud③
```

① TaaS 公有云服务测试版将于 2017 年 3 月底正式上线。

② Caicloud 提供的 TaaS 平台只支持 TensorFlow 0.12.0 及以上版本。

③ 在 Caicloud 提供的开发环境中可以加载 caicloud_dist_tensorflow_base 模块。Caicloud 同时也提供了用于开发的 caicloud_dist_tensorflow_base 源代码及 pip 安装包,感兴趣的读者可以参考才云科技官网 caicloud.io。

```

class CaicloudDistMnist(caicloud.CaicloudDistTensorflowBase):
    # 定义神经网络前向传播的过程。
    def _inference(self, images):
        w = tf.Variable(tf.zeros([784, 10]), name='weights')
        tf.summary.histogram("weights", w)
        b = tf.Variable(tf.zeros([10]), name='bias')
        tf.summary.histogram("bias", b)
        predictions = tf.matmul(images, w) + b
        return predictions

    # 定义优化函数。在同步模式下需要使用 SyncReplicasOptimizerV2 来同步不同 worker。
    def _create_optimizer(self, sync, num_replicas):
        optimizer = tf.train.AdagradOptimizer(0.01);
        if sync:
            num_workers = num_replicas
            optimizer = tf.train.SyncReplicasOptimizerV2(
                optimizer,
                replicas_to_aggregate=num_workers,
                total_num_replicas=num_workers,
                name="mnist_sync_replicas")
        return optimizer

    # build_model 函数中, global_step 参数是全局的训练轮数, 在定义优化函数时需要将训
    # 练轮数作为参数传入, 这样 global_step 可以通过优化器自动维护。is_chief 参数给出了
    # 当前节点是否为主计算节点。sync 参数给出了是否使用同步模式。当 sync 为 True 时模型
    # 需要采用同步模式更新, 否则使用异步模式。num_replicas 参数给出了该 TensorFlow 集
    # 群中计算节点的个数。build_model 函数需要返回一个 tensorflow.train.Optimizer
    # 对象, Taas 平台将自动使用该对象来完成同步模式下初始化的工作。
    def build_model(self, global_step, is_chief, sync, num_replicas):
        # 定义当前 worker 的训练轮数, 该变量可以用来输出训练信息。
        self._step = 0

        # 加载 MNIST 数据, 数据存放的地址需要为 Caicloud 提供的存储路径。
        mnist = input_data.read_data_sets(
            "/caicloud/dist-tf/base/examples/mnist/data", one_hot=True)
        self._mnist = mnist

        # 定义神经网络的输入和模型的前向传播。
        input_images = tf.placeholder(
            tf.float32, [None, 784], name='images')
        self._input_images = input_images
        predictions = self._inference(input_images)

        # 定义损失函数。

```



```

labels = tf.placeholder(tf.float32, [None, 10], name='labels')
self._labels = labels
cross_entropy = tf.reduce_mean(
    tf.nn.softmax_cross_entropy_with_logits(predictions, labels))
self._loss = tf.reduce_mean(
    cross_entropy, name='cross_entropy_mean')

# 定义优化函数。在调用优化函数时，我们需要将 global_step 传入优化函数，否则系统
# 将无法获取全局的训练轮数。
optimizer = self._create_optimizer(sync, num_replicas)
train_op = optimizer.minimize(
    cross_entropy, global_step=global_step)
self._train_op = train_op

# 定义计算正确率的方法。
correct_prediction = tf.equal(tf.argmax(predictions, 1),
                              tf.argmax(labels, 1))
accuracy = tf.reduce_mean(tf.cast(correct_prediction, tf.float32))
self._accuracy = accuracy

# 返回优化函数。
return optimizer

# Caicloud TaaS 平台在生成 TensorFlow 会话 (Session) 之后会自动地执行默认的初
# 始化操作，例如参数初始化、同步模式更新队列初始化等。但如果用户有其他需要在开始模
# 型训练之前完成的操作，例如模型预加载，则可以通过定义 get_init_fn 函数来完成。
# get_init_fn 函数的参数 checkpoint_path 提供了用于模型预加载的 checkpoint 文件
# 地址或 checkpoint 文件所在目录的路径。get_init_fn 函数的返回为一个函数，该函数
# 必须接收一个参数，即一个可用的会话 (Session)。该函数将在启动模型训练之前被调用。
# 以下代码展示了如何通过该函数进行模型预加载。
def get_init_fn(self, checkpoint_path):
    # 获取模型文件地址。
    if tf.gfile.IsDirectory(checkpoint_path):
        checkpoint_path = tf.train.latest_checkpoint(checkpoint_path)
    else:
        checkpoint_path = checkpoint_path
    print('warm-start from checkpoint {}'.format(checkpoint_path))

    # 模型预加载。
    saver = tf.train.Saver(tf.trainable_variables())
    def InitAssignFn(sess):
        saver.restore(sess, checkpoint_path)

    # 返回执行模型预加载的函数。

```

```

return InitAssignFn

# Caicloud TaaS 平台会自动地循环调用 train 函数来训练深度学习模型。train 函数中，
# 用户只需要定义每一轮训练中需要执行的步骤。训练的步骤可以包括调用优化函数以及计算滑
# 动平均等。train 函数需要返回一个布尔类型，表示当前训练是否需要结束。这样可以支持当
# 正确率比较稳定之后提前结束训练。
def train(self, session, global_step, is_chief):
    # 执行模型训练步骤并记录时间。
    start_time = time.time()
    batch_xs, batch_ys = self._mnist.train.next_batch(100)
    feed_dict = {self._input_images: batch_xs, self._labels: batch_ys}
    _, loss_value, np_global_step = session.run(
        [self._train_op, self._loss, global_step],
        feed_dict=feed_dict)
    self._step += 1
    duration = time.time() - start_time

    # 每隔一段时间输出训练信息。
    if self._step % 50 == 0:
        print('Step %d: loss = %.2f (%.3f sec), global step: %d.' % (
            self._step, loss_value, duration, np_global_step))
    if self._step % 1000 == 0:
        print("Accuracy on Validation Data: %.3f" % session.run(
            self._accuracy, feed_dict={
                self._input_images: self._mnist.validation.images,
                self._labels: self._mnist.validation.labels}))
    return False

# 在模型训练成功结束后希望能够计算最终训练得到的模型在 MNIST 测试数据集上的正确率。
# 这个过程可以通过定义 after_train 函数来实现。类似的，用户也可以在 after_train
# 函数中保存最终的模型。
def after_train(self, session, is_chief):
    print("train done.")
    print("Accuracy on Test Data: %.3f" % session.run(
        self._accuracy, feed_dict={
            self._input_images: self._mnist.test.images,
            self._labels: self._mnist.test.labels}))

```

将以上代码提交到 Caicloud 的 TaaS 平台之后，可以看到类似图 10-10 所示的监控页面。在监控页面中，TaaS 提供了对资源利用率、训练进度、训练模式、程序日志以及 TensorBoard 等多种信息的综合展示，用户可以更好地了解训练的进度和状态。因为篇幅所限，对 TaaS 感兴趣的读者可以在 Caicloud 的官方网站 caicloud.io 上找到更多信息和教程。

TensorFlow: 实战 Google 深度学习框架

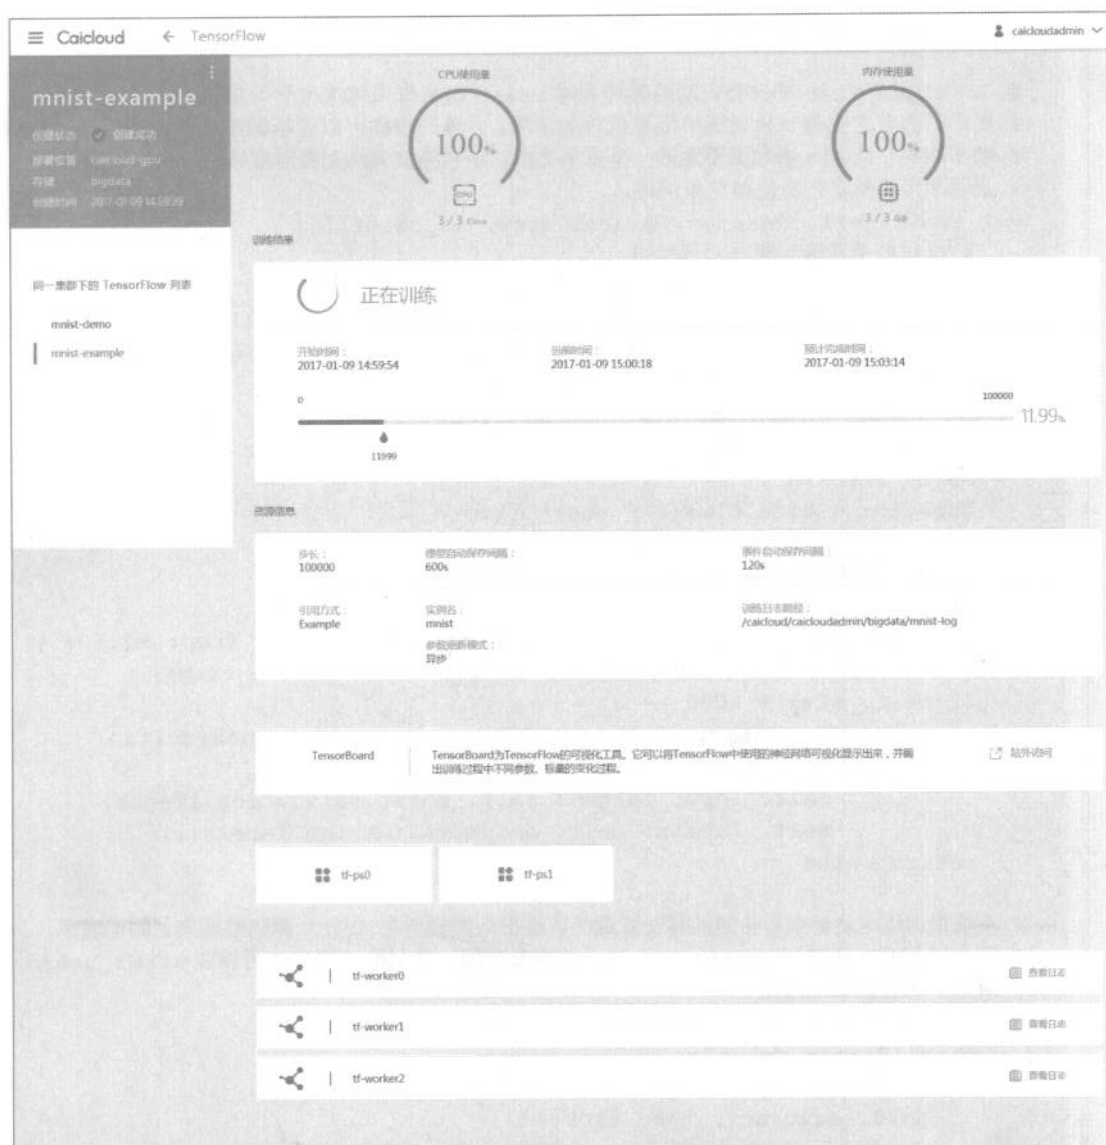


图 10-10 Caicloud 提供的 TaaS 分布式 TensorFlow 任务详情页面

小结

在本章中介绍了 TensorFlow 如何通过 GPU 或/和分布式集群的方式加速深度学习模型